



TECNOLÓGICO NACIONAL DE MÉXICO
en Celaya



TECNOLÓGICO NACIONAL DE MÉXICO EN CELAYA
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

**“DISEÑO DE UNA METAHEURÍSTICA
EVOLUTIVA ORIENTADA A LA DISTRIBUCIÓN
DE AEROGENERADORES EN CAMPOS EÓLICOS”**

**TESIS PROFESIONAL
PARA OBTENER EL GRADO DE:
MAESTRO EN INGENIERÍA INDUSTRIAL**

**PRESENTA:
ING. ABELARDO BUENTELLO DUQUE**

**DIRECTOR DE TESIS:
DR. SALVADOR HERNÁNDEZ GONZÁLEZ**

**CO-DIRECTOR DE TESIS:
DR. JOSÉ ALFREDO JIMÉNEZ GARCÍA**

CELAYA, GTO., MÉXICO, SEPTIEMBRE, 2019



"2019, Año del Caudillo del Sur, Emiliano Zapata"

Asunto: Autorización de impresión de trabajo profesional.

Celaya Gto., **29 de AGOSTO 2019**

M.C. MOISES TAPIA ESQUIVIAS
JEFE DEL DEPARTAMENTO DE INGENIERIA INDUSTRIAL.
Presente.

De acuerdo a la convocatoria hecha por esta jefatura a fin de aprobar o no la impresión del trabajo profesional titulado:

"DISEÑO DE UNA METAHEURÍSTICA EVOLUTIVA ORIENTADA A LA DISTRIBUCIÓN DE AEROGENERADORES EN CAMPOS EÓLICOS."

*Presentado por el (a) pasante **C. ING. BUENTELLO DUQUE ABELARDO (M1703073)** alumno (a) del programa de Maestría en Ingeniería Industrial que ofrece nuestro Instituto. Hacemos de su conocimiento que éste jurado ha tenido a bien aprobar la impresión de dicho trabajo para los efectos consiguientes.*

ATENTAMENTE

DR. SALVADOR HERNANDEZ GONZALEZ
Presidente



M.C. VICENTE FIGUEROA FERNANDEZ
Secretario

M.C. MOISES TAPIA ESQUIVIAS
Vocal

SECRETARIA DE
EDUCACION PUBLICA
TECNOLÓGICO NACIONAL
DE MEXICO
INSTITUTO TECNOLÓGICO
DE CELAYA
COORDINACION DE MAESTRIA
DE INGENIERIA INDUSTRIAL

M.C. MANUEL DARIO HERNANDEZ RIPALDA
Vocal Suplente

Ccp. Escolares
Archivo.
VFF*MTE*dmvp



Resumen

La energía eólica se ha convertido mundialmente en la energía renovable con mayor participación en los países que buscan la sustentabilidad ambiental. Sin embargo, producir la máxima cantidad de energía esperada aprovechando el recurso del viento en un campo eólico cuyas dimensiones de terreno disponibles son limitadas es un reto al que los diseñadores de campos eólicos deben enfrentarse. Para el diseño eficiente de un campo eólico se requiere distribuir un conjunto de aerogeneradores de tal manera que produzcan la máxima cantidad de energía instalada. En la práctica resulta difícil lograr esto, ya que es necesario considerar fenómenos que provocan reducciones de energía en un campo eólico, tal como lo es el efecto estela. El efecto estela es una turbulencia en el viento que se presenta cuando dos o más turbinas se encuentran localizadas a una distancia aledaña. En esta investigación se propone la implementación de una metaheurística evolutiva así como un modelo de efecto estela para optimizar la ubicación de aerogeneradores en campos eólicos hipotéticos. Los resultados de las instancias solucionadas demostraron que el método metaheurístico y la técnica de diseño de experimentos proporcionan soluciones de energía de alta calidad en tiempos de cómputo razonables. El método metaheurístico es comparado con un algoritmo clásico.

Abstract

Wind power has become the renewable energy with more participation in countries looking for environmental sustainability. However, producing the maximum expected amount of energy by taking advantage of the wind resource on a windfarm with the dimensions of available land being limited is a challenge that windfarm designers have to face. The efficient design of a wind farm requires a set of wind turbines to be distributed in such a way as to produce the maximum amount of installed energy. This is difficult to achieve in practice, as phenomena that provoke energy drops in a wind farm must be taken into consideration, such as the wake effect. The wake effect is turbulence in the wind that arises when two or more turbines are located close to each other. This research proposes the implementation of an evolutionary metaheuristic while also examining a wake effect model to optimize the location of wind turbines in hypothetical wind farms. The results of the solved instances demonstrated that the metaheuristic method and the design of experiments technique provide high quality energy solutions in reasonable computing times. The metaheuristic method is compared with a classical algorithm.

Índice

Capítulo 1. Introducción	9
1.1 Planteamiento del problema	10
1.2 Objetivos.....	16
1.2.1 Objetivo general	16
1.2.2 Objetivos específicos.....	16
1.3 Hipótesis	16
1.4 Justificación.....	17
1.5 Alcances y limitaciones	18
1.5.1 Alcances	18
1.5.2 Limitaciones	19
Marco Teórico	20
Capítulo 2. Campos eólicos	20
2.1 Conceptos de diseño	21
2.2 Energía.....	21
2.3 Eficiencia energética.....	22
2.4 Energía eólica	23
2.5 Aerogeneradores	23
2.5.1 Componentes principales de los aerogeneradores	25
2.5.2 Tipos y clasificación de aerogeneradores	26
2.6 Campo eólico.....	29
2.7 Efecto estela.....	31
Capítulo 3. Optimización.....	34
3.1 Modelos de optimización	35
3.2 Optimización	38
3.2.1 Óptimo local y óptimo global.....	39
3.2.2 Optimización combinatoria y problemas combinatorios.....	40
3.3 Complejidad computacional	42
3.4 Problemas P, NP, NP-completos y NP-duros.....	44
3.5 Programación entera	47
3.6 Heurísticas	48
3.7 Metaheurísticas	51
3.7.1 Metaheurísticas evolutivas y algoritmos genéticos	55
3.8 Diagrama de funcionamiento de los Algoritmos Genéticos.....	56
3.9 Diseño de Experimentos	57
3.9.1 Diseño factorial 2^k	63
3.10 Estado del arte	68
Capítulo 4. Método.....	80
4.1 Formulación del problema de optimización en campos eólicos.....	81
4.2 Identificación de las variables significativas a abordar en el problema	82
4.3 Definición de las estrategias y procedimientos heurísticos	82
4.3.1 Discretización del campo eólico.....	82

4.4	Diseño de la metaheurística evolutiva (Algoritmo Genético)	84
4.5	Implementación de la metaheurística evolutiva en un escenario de estudio	90
4.6	Validación de los resultados obtenidos en la implementación de la metaheurística evolutiva	91
4.7	Implementación de la metaheurística evolutiva en escenarios más complejos y validación de los resultados obtenidos de estas implementaciones.....	91
4.8	Conclusiones y documentación	91
Capítulo 5. Resultados y conclusiones		92
5.1	Resultados.....	93
5.1.1	Caso 1	98
5.1.2	Caso 2	105
5.1.2.1	Caso 2(a).....	107
5.1.2.2	Caso 2(b)	110
5.1.2.3	Caso 2(c).....	112
5.1.3	Caso 3	114
5.1.3.1	Análisis comparativo de rendimiento de campos eólicos de acuerdo al número de turbinas instaladas	115
5.1.3.2	Análisis de distribución de aerogeneradores de acuerdo a la dirección del viento incidente	131
5.1.4	Resolución del problema de optimización del diseño de campos eólicos utilizando un método numérico. Comparación de resultados; Algoritmo Genético vs Algoritmo GRG Non-linear.....	142
5.2	Conclusiones.....	155
Bibliografía.....		161
ANEXO A: Código de programación en R para el Caso 1 (Gatscha, 2016).....		164
ANEXO B: Código de programación en R para el Caso 2 (Gatscha, 2016).....		165
ANEXO C: Código de programación en R para el Caso 3 (Gatscha, 2016).....		166
ANEXO D: Publicación de artículo derivado de tesis en la revista Engineering and Technology		167
ANEXO E: Publicación de artículo derivado de tesis en la revista Pistas Educativas.....		168

Índice de figuras

Figura 1. 1	Curva de potencia de un aerogenerador SENVION Modelo 3.2M114 NES. Fuente: Elaboración propia.	12
Figura 1. 2	Efecto estela entre dos turbinas. Fuente: Elaboración propia.	13
Figura 1. 3	Diseño propuesto de un campo eólico para análisis. Fuente: Elaboración propia.	14
Figura 1. 4	Efectos estela del escenario de campo eólico propuesto. Fuente: Elaboración propia.	15
Figura 2. 1	Aerogenerador de eje vertical. Fuente: Nieves (2011).....	27
Figura 2. 2	Aerogenerador de eje horizontal. Fuente: Nieves (2011)	27
Figura 2. 3	Aerogenerador tipo Barlovento. Fuente: Nieves (2011).....	28

Figura 2. 4 Aerogenerador tipo Sotavento. Fuente: Nieves (2011).....	29
Figura 2. 5 Campo eólico: La venta, Oaxaca. Fuente: (Google Maps, 2018).	30
Figura 2. 6 Representación esquemática del efecto estela. Fuente: Elaboración propia.	32
Figura 3. 1 Estructura de un modelo matemático	36
Figura 3. 2 Gráfica del valor de la función objetivo en un intervalo factible. Fuente: Elaboración propia.....	40
Figura 3. 3 Diagrama de complejidad computacional. Comparación de crecimiento entre dos algoritmos. Fuente: Elaboración propia.	44
Figura 3. 4 Diagrama de relación entre las clases de problemas P, NP, NP-completos y NP- duros, para el caso en que $P \neq NP$. Fuente: Elaboración propia.	47
Figura 3. 5 Diagrama del procedimiento de mejora local. Fuente: Elaboración propia.	53
Figura 3. 6 Diagrama de funcionamiento esquemático de los algoritmos genéticos. Fuente: (Andaluz, 2018).	57
Figura 3. 7 Modelo general de un proceso o sistema. Fuente: (Montgomery, 2011).....	58
Figura 3. 8 Pautas generales para diseñar un experimento. Fuente: (Montgomery, 2011) ..	61
Figura 3. 9 Procedimiento de análisis para un diseño $2k$. Fuente: (Montgomery, 2011)	66
Figura 4. 1 Etapas del método de trabajo. Elaboración propia.	81
Figura 4.2 Campo eólico discreto. Fuente: Elaboración propia.	83
Figura 4. 3 Individuos generados aleatoriamente para la población inicial. Fuente: Elaboración propia.....	88
Figura 4. 4 Padres seleccionados para compartir su información genética en la posición 10 del cromosoma. Fuente: Elaboración propia.	89
Figura 4. 5 Nuevos individuos procreados. Fuente: Elaboración propia.....	89
Figura 4. 6 Hijo #1 mutado en la posición 14. Fuente. Elaboración propia.	89
Figura 4. 7 Pseudocódigo del algoritmo genético. Fuente: Bilbao & Alba (2011)	90
Figura 5. 1 Fragmento del experimento 25 con 3 réplicas y 8 puntos centrales	94
Figura 5. 2 ANOVA para la variable de respuesta 1: Energía	96
Figura 5. 3 ANOVA para la variable de respuesta 2: Tiempo de CPU	97
Figura 5. 4 Características y dimensiones del campo eólico a optimizar	99
Figura 5. 5 Rosa de los vientos para el Caso 1	99
Figura 5. 6 Mejor solución encontrada por el algoritmo	102
Figura 5. 7 Mejor solución encontrada desde la iteración 61	102
Figura 5. 8 Vector solución que representa la mejor solución	103
Figura 5. 9 Representación alternativa del diseño óptimo del campo eólico	103
Figura 5. 10 Progreso de los valores de aptitud en cuanto a energía.....	103
Figura 5. 11 Cantidad de individuos en cada iteración	104
Figura 5. 12 Influencia de la mutación variable en los valores de eficiencia energética ...	104
Figura 5. 13 Influencia de la selección de individuos en los valores de eficiencia energética	105
Figura 5. 14 Influencia del cruce de individuos con 3 partes de cruce.....	105
Figura 5. 15 Características y dimensiones del campo eólico	106
Figura 5. 16 Rosa de los vientos utilizada para las variantes del Caso 2	106
Figura 5. 17 Mejor distribución del campo eólico.....	108
Figura 5. 18 Representación alternativa de la distribución óptima del campo eólico	109
Figura 5. 19 Evolución de las eficiencias durante todas las generaciones	109
Figura 5. 20 Mejor distribución del campo eólico.....	111
Figura 5. 21 Representación alternativa de la solución	111

Figura 5. 22 Evolución de las eficiencias energéticas del campo eólico por generación...	112
Figura 5. 23 Mejor distribución del campo eólico.....	113
Figura 5. 24 Evolución de las eficiencias del campo eólico por generación.....	114
Figura 5. 25 Campo eólico a optimizar	115
Figura 5. 26. Dirección del viento considerada para el análisis comparativo	115
Figura 5. 27. Mejor solución de distribución para la instancia #1: 40 aerogeneradores	117
Figura 5. 28. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #1	117
Figura 5. 29. Mejor solución de distribución para la instancia #2: 37 aerogeneradores	118
Figura 5. 30. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #2	119
Figura 5. 31. Mejor solución de distribución para la instancia #3: 35 aerogeneradores	120
Figura 5. 32. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #3	120
Figura 5. 33. Mejor solución de distribución para la instancia #4: 33 aerogeneradores	121
Figura 5. 34. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #4	121
Figura 5. 35. Mejor solución de distribución para la instancia #5: 31 aerogeneradores	122
Figura 5. 36. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #5	122
Figura 5. 37. Mejor solución de distribución para la instancia #6: 29 aerogeneradores	123
Figura 5. 38. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #6	123
Figura 5. 39. Mejor solución de distribución para la instancia #7: 27 aerogeneradores	124
Figura 5. 40. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #7	124
Figura 5. 41 Mejor solución de distribución para la instancia #8: 25 aerogeneradores	125
Figura 5. 42 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #8	125
Figura 5. 43 Mejor solución de distribución para la instancia #9: 23 aerogeneradores	126
Figura 5. 44 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #9	126
Figura 5. 45 Mejor solución de distribución para la instancia #10: 21 aerogeneradores ...	127
Figura 5. 46 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #10	127
Figura 5. 47 Mejor solución de distribución para la instancia #11: 19 aerogeneradores ...	128
Figura 5. 48 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #11	128
Figura 5. 49 Mejor solución de distribución para la instancia #12: 17 aerogeneradores ...	129
Figura 5. 50 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #12	129
Figura 5. 51. Gráfico de análisis de regresión: Núm. de turbinas-Energía.....	130
Figura 5. 52. Gráfico de análisis de regresión: Núm. de turbinas-Déficit de energía	131
Figura 5. 53 Mejor solución de distribución con viento a 0°	132
Figura 5. 54 Viento incidente a 0°	132
Figura 5. 55 Mejor solución de distribución con viento proveniente del Noreste.....	133
Figura 5. 56 Viento incidente del Noreste	133

Figura 5. 57 Mejor solución de distribución con viento a 90°	134
Figura 5. 58 Viento incidente a 90°	134
Figura 5. 59 Mejor solución de distribución con viento a 135°	135
Figura 5. 60 Viento incidente a 135°	135
Figura 5. 61 Mejor solución de distribución con viento a 180°	136
Figura 5. 62 Viento incidente a 180°	136
Figura 5. 63 Mejor solución de distribución con viento proveniente del Suroeste	137
Figura 5. 64 Viento incidente del Suroeste.....	137
Figura 5. 65 Mejor solución de distribución con viento proveniente del Oeste.....	138
Figura 5. 66 Viento incidente del Oeste	138
Figura 5. 67 Mejor solución de distribución con viento proveniente del Noroeste.....	139
Figura 5. 68 Viento incidente del Noroeste.....	139
Figura 5. 69. Gráfico de análisis de regresión: Dirección del viento-Energía.....	141
Figura 5. 70. Gráfico de análisis de regresión: Dirección del viento-Déficit de energía (efecto estela).....	142
Figura 5. 71 Curva de potencia de la turbina utilizada para la comparación de algoritmos	143
Figura 5. 72 Tiempos de ejecución y promedio aritmético para cada instancia.....	145
Figura 5. 73 Tiempo de ejecución que el algoritmo GRG invirtió para solucionar cada instancia.....	146
Figura 5. 74 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 3*4	147
Figura 5. 75 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 4*4	147
Figura 5. 76 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 5*5	148
Figura 5. 77 Solución de distribución encontrada por el algoritmo GRG para la instancia 6*6	149
Figura 5. 78 Solución de distribución encontrada por el Algoritmo Genético para la instancia 6*6.....	149
Figura 5. 79 Solución de distribución encontrada por el algoritmo GRG para la instancia 6*10	150
Figura 5. 80 Solución de distribución encontrada por el Algoritmo Genético para la instancia 6*10.....	151
Figura 5. 81 Solución de distribución encontrada por el algoritmo GRG para la instancia 7*7	152
Figura 5. 82 Solución de distribución encontrada por el Algoritmo Genético para la instancia 7*7.....	153
Figura 5. 83 Solución de distribución encontrada por el algoritmo GRG para la instancia 7*10	154
Figura 5. 84 Solución de distribución encontrada por el Algoritmo Genético para la instancia 7*10.....	155

Índice de tablas

Tabla 2. 1 Principales características de los aerogeneradores y nomenclatura	24
Tabla 3. 1 Principales estadísticos. Fuente: Elaboración propia.	67
Tabla 3. 2 Estado del arte. Fuente: Elaboración propia.....	68
Tabla 5. 1 Factores y niveles de los factores para el experimento	94
Tabla 5.2 Arreglos de los factores que obtuvieron la máxima energía esperada para el Caso 1	95
Tabla 5. 3 Estadísticos correspondientes a la variable de respuesta 1: Energía	97
Tabla 5. 4 Estadísticos correspondientes a la variable de respuesta 2: Tiempo de CPU.....	98
Tabla 5. 5 Código que inicia una optimización de acuerdo a los parámetros de entrada del Caso 1	98
Tabla 5. 6 Valores de entrada para el Caso 1	99
Tabla 5. 7 Valores de entrada para el Caso 2(a).....	108
Tabla 5. 8 Valores de entrada para el Caso 3	115
Tabla 5. 9 Análisis comparativo de rendimiento de acuerdo al número de turbinas instaladas	116
Tabla 5. 10 Tabla resumen de los resultados de rendimiento del campo eólico al variar las direcciones de viento	140
Tabla 5. 11 Comparación de resultados entre el método numérico GRG Non-linear y la metaheurística evolutiva	143
Tabla 5. 12 Valores de los parámetros utilizados en el Solver de Excel.....	144
Tabla 5. 13 Valores recomendados para los parámetros claves del Algoritmo Genético en R	157
Tabla 5. 14 Análisis de abastecimiento de energía eléctrica en México de acuerdo a las soluciones de los casos 1 y 2	157
Tabla 5. 15 Análisis monetario.....	158

Capítulo 1.

Introducción

1.1 Planteamiento del problema

De acuerdo con M. Fischetti (2016) la sustentabilidad ambiental exige la considerable reducción en el uso de combustibles fósiles, los cuales son sumamente contaminantes e insostenibles. Se han propuesto soluciones para contrarrestar dichos efectos, los cuales incluyen la producción de energía verde, en mayor participación la energía eólica.

Sin embargo, se ha observado un área de oportunidad en la generación de esta energía renovable, debido a que muchos campos eólicos no producen la cantidad de producción esperada e instalada en cuanto a potencia energética se refiere (Megawatts, Kilowatts, Gigawatts). Dichas metas de producción de energía no alcanzadas podrían repercutir en aspectos pocos satisfactorios, por ejemplo: retraso en recuperación de la inversión, dependencia de combustibles fósiles, costo de producción alto, entre otros.

Este problema estratégico, resulta sumamente difícil atacar en la práctica, desde distintos puntos de vista como el económico, puesto que para distribuir eficientemente un conjunto de aerogeneradores en un campo eólico se deben de tomar en cuenta una enorme cantidad de condiciones complejas y la presencia de factores no lineales, dando como resultado una inversión monetaria considerable debido al consumo excesivo de recursos necesarios (tiempo, mano de obra, equipos, etc.) para el diseño óptimo del campo eólico.

Uno de los factores típicos no lineales a considerar para el diseño óptimo de un campo eólico es la interacción entre los campos de operación de los aerogeneradores, conocido como efecto estela. De acuerdo a estimaciones, en grandes parques eólicos marinos, la pérdida de energía promedio debido a los efectos estela entre turbinas es de alrededor del 10-20% de la producción total de energía (Barthelmie, y otros, 2009). Sin embargo, dichas tasas de pérdida de energía también dependen en mayor medida de las condiciones y características propias del campo eólico como: velocidad del viento, distancia entre aerogeneradores, modelo de aerogeneradores, etc.

El efecto estela es un fenómeno derivado de la interacción para lo cual, si dos aerogeneradores son localizados a cierta distancia contigua, al presentarse cierta corriente de viento proveniente de una dirección dominante y con una determinada velocidad inicial y a su vez esta corriente interactúa con un primer aerogenerador corriente arriba, dicho

aerogenerador crea una turbulencia en el viento, derivada de la absorción de energía cinética, provocando la reducción considerable de velocidad y fuerza en dicho viento. El viento debilitado, al continuar su curso será absorbido por un segundo aerogenerador corriente abajo, el cual tendrá a su disposición menor energía cinética para operar, ocasionando una notable disminución en su producción energética nominal de salida (Megawatt, Kilowatt, etc.).

Si un conjunto considerable de aerogeneradores en un campo eólico resultaran afectados por este fenómeno, se estaría desperdiciando una cantidad significativa de energía que podría ser aprovechada eficientemente, dado que como bien se comprende, la producción energética de un aerogenerador está en función de la velocidad del viento que incida sobre él (En la Figura 1.1 se muestra un ejemplo de curva de potencia para un aerogenerador marca SENVION.)

En dicha figura se puede apreciar el comportamiento de producción energética para el aerogenerador modelo 3.2M114 NES de la marca SENVION. La potencia energética (kW) que produzca tal aerogenerador está en función de la velocidad del viento que incida sobre él, es decir si el aerogenerador absorbe energía cinética del viento (U), el cual contiene cierta velocidad, digamos 10 m/s (eje x), su producción de energía será equivalente a 1638.4 kW (eje y).

Asimismo, cabe destacar que esta curva de potencia nos muestra que este aerogenerador en particular está diseñado para mantener una potencia nominal de energía de 3,200 kW cuando el viento incidente (U) contiene una velocidad mayor o igual a 12 m/s pero menor que 22 m/s ($12 \text{ m/s} \leq U < 22 \text{ m/s}$). De igual manera, en la curva de potencia se puede apreciar que este modelo de aerogenerador comienza a producir energía cuando el viento incidente supera los 3 m/s. Por último, en la curva de potencia se puede observar que cuando el viento incidente contiene una velocidad igual o mayor a 22 m/s, el aerogenerador automáticamente detiene su operación, debido a que al trabajar con una velocidad igual o mayor a 22 m/s genera daños en sus componentes eléctricos y/o mecánicos.

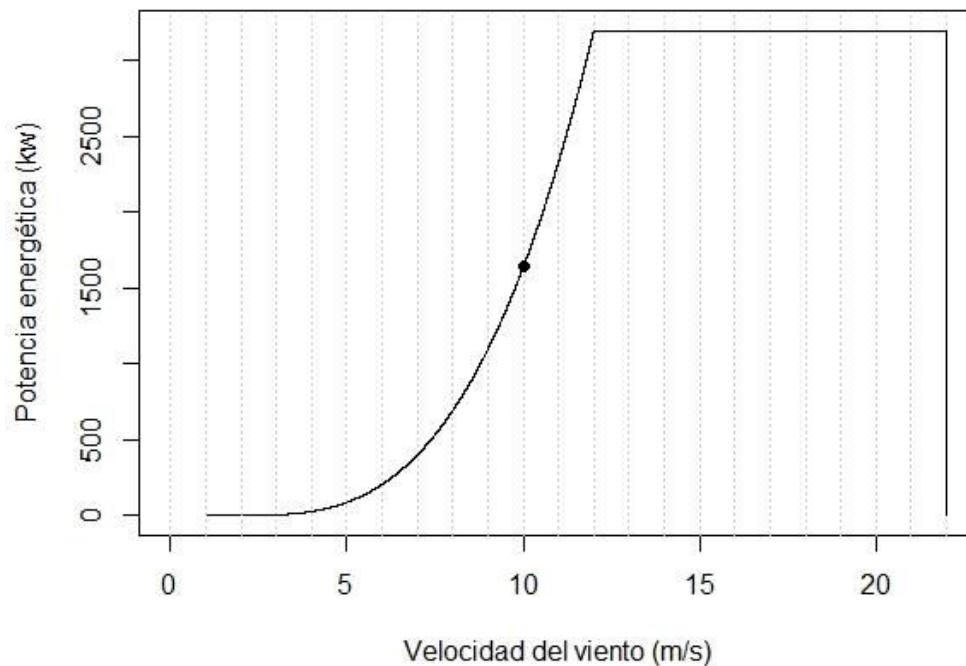


Figura 1. 1 Curva de potencia de un aerogenerador SENVION Modelo 3.2M114 NES.
Fuente: Elaboración propia.

La figura 1.2 muestra de manera ilustrativa el fenómeno de efecto estela cuando un aerogenerador tiene interferencia sobre otro en la misma dirección del viento incidente. En primera instancia se presenta un viento incidente a cierta velocidad (U_0), después de que esta corriente de viento pasa por el Aerogenerador A, se produce una sombra o turbulencia (efecto estela) que provoca una reducción de velocidad en el viento disponible (U_B) para el Aerogenerador B. En pocas palabras, U_0 representa la velocidad inicial del viento incidente sobre el Aerogenerador A y U_B es la velocidad del viento resultante que incide sobre el Aerogenerador B una vez que ha pasado por el Aerogenerador A.

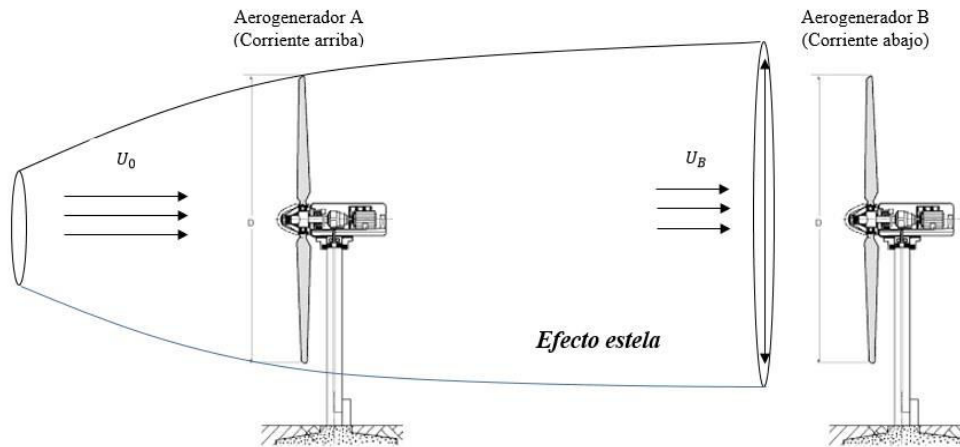


Figura 1. 2 Efecto estela entre dos turbinas. Fuente: Elaboración propia.

La figura 1.3 presenta un diseño propuesto (escenario) para un campo eólico de 600 m x 600 m, en el cual se puede observar la discretización del mismo (cuadrículas), con la finalidad de precisar todas las posibles localizaciones o ubicaciones centrales (anillos) donde podría asignarse o instalarse un aerogenerador. Para este diseño en específico, se tiene un total de 25 posibles localizaciones discretas con dimensiones de 120 m x 120 m cada una, de las cuales en 11 de ellas se tiene asignado o instalado un aerogenerador (representados con una imagen a escala). Asimismo, en el escenario del campo eólico propuesto se manifiesta cierto viento inicial (U_0) con una dirección dominante de Norte a Sur. Para este escenario en particular, el número de combinaciones o formas posibles de diseñar el campo eólico corresponde a un total de 4,457, 400, la cual es una cantidad elevada para resolver en la práctica e incluso para resolver con un algoritmo exacto.

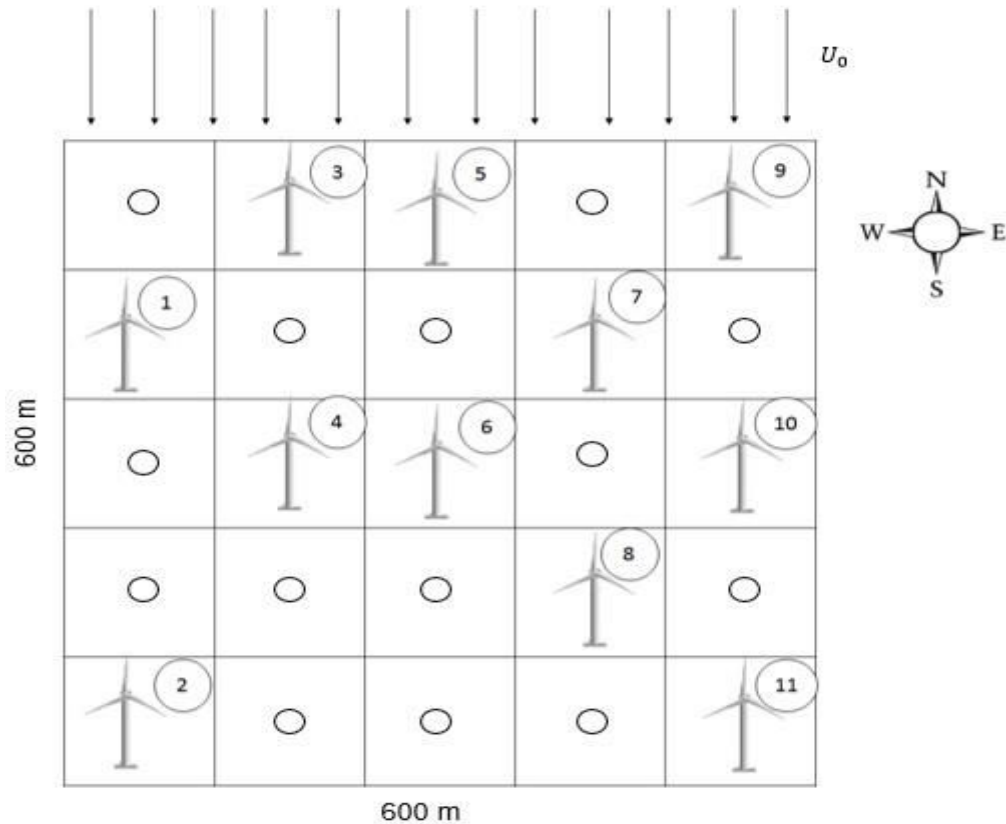


Figura 1. 3 Diseño propuesto de un campo eólico para análisis. Fuente: Elaboración propia.

En la Figura 1.4 se pueden apreciar los efectos estela del escenario anteriormente descrito. En esta figura los aerogeneradores instalados en sus localizaciones particulares se representan con una esfera. La escala de magnitud nos brinda la información respecto a la intensidad de viento que incide en cada uno de los aerogeneradores. Debido a que el viento inicial incidente proviene de la dirección Norte, los aerogeneradores nombrados anteriormente como 1, 5, 9 captan la mayor energía cinética del viento inicial, mientras que los aerogeneradores 1, 7, 4, 6, 10 disponen de una cantidad de energía cinética menor y por ende una reducida velocidad del viento para operar y generar la energía esperada, debido a los efectos estela que produjeron los aerogeneradores 1, 5, 9. Los aerogeneradores 2 y 11 disponen de una cantidad de energía cinética y velocidad de viento significativamente deficientes. Dichos déficits considerables son provocados por la combinación de los efectos estela ocasionados por los aerogeneradores que se encuentran instalados en el sector norte del campo eólico, los cuales son mayormente beneficiados, debido a que el viento inicial predominante proviene de dicha dirección cardinal.




Figura 1. 4 Efectos estela del escenario de campo eólico propuesto. Fuente: Elaboración propia.

Lo ideal sería que cada uno de los aerogeneradores dispusiera de las mejores condiciones (velocidad) del viento para producir energía e impedir que exista una diferencia significativa de producción energética entre ellos. Al maximizar la producción de energía en cada uno de los aerogeneradores mediante una adecuada distribución, simultáneamente se estaría maximizando la producción energética total instalada del campo eólico.

Por lo tanto, es evidente que la producción de energía puede incrementarse significativamente si se diseña una distribución adecuada de aerogeneradores en un campo eólico, con la finalidad de que se reduzcan los fenómenos de efectos estela entre aerogeneradores tanto como sea posible.

Sin embargo, para brindar una buena solución al problema de optimización de campos eólicos no sólo el efecto estela es un inconveniente, otro de ellos es que este problema se plantea como un problema de optimización combinatoria debido a que su resolución es muy compleja computacionalmente. De este modo al tratarse de un problema NP-duro se pretende resolver adoptando una estrategia de búsqueda aproximada, la cual brinde una buena solución con el menor esfuerzo computacional posible comparado con el que se obtendría si se empleara un método exacto de optimización.

Por dicha razón, se propone el diseño de una metaheurística evolutiva, específicamente un algoritmo genético, que proporcione una buena solución de producción energética al problema de la distribución de aerogeneradores en campos eólicos. Asimismo, la solución a obtener considerando un enfoque metaheurístico, incluye la obtención de la mejor distribución de aerogeneradores para cada uno de los distintos escenarios de campos eólicos. Lo anterior se pretende lograr mediante la asignación discreta de cada uno de los aerogeneradores que se pretenden instalar en un sitio determinado (terreno), así como la consideración del modelo de Jensen para calcular los déficits de energía ocasionados por los efectos estela.

1.2 Objetivos

1.2.1 Objetivo general

Diseñar una metaheurística evolutiva para brindar una solución de buena calidad en un tiempo de cómputo razonable al problema de optimización de la distribución de aerogeneradores en campos eólicos.

1.2.2 Objetivos específicos

- a) Plantear el problema de optimización en campos eólicos.
- b) Identificar las variables asociadas al problema de optimización.
- c) Definir estrategias y procedimientos heurísticos necesarios para atacar el problema.
- d) Diseñar la metaheurística evolutiva.
- e) Implementar la metaheurística evolutiva en un escenario de estudio.
- f) Validar los resultados obtenidos de la implementación de la metaheurística evolutiva.

1.3 Hipótesis

Existe una metaheurística evolutiva que validada con el diseño de experimentos brinda una solución de mayor calidad al problema de optimización de campos eólicos en comparación

a las soluciones encontradas por un método metaheurístico similar y cuyas soluciones se encuentran reportadas en la literatura.

1.4 Justificación

Una importante fase del diseño de un campo eólico está enfocado a resolver el problema de optimización de la distribución de aerogeneradores, por lo que muchas veces no resulta fácil encontrar una solución óptima y por consecuente los desarrolladores o diseñadores de campos eólicos no son capaces de resolver dicho problema en un tiempo y costos razonables. Al no contar con una inversión monetaria suficiente, estos inconvenientes ocasionan una inadecuada distribución de aerogeneradores en el campo eólico, dejándolo vulnerable a una considerable reducción de producción energética total a comparación de la capacidad instalada, impactando así de manera negativa a distintos ámbitos como los sociales y económicos, entre los que destacan los siguientes:

a) Sociales:

- Dependencia de los combustibles fósiles para crear energía.
- Incumplimiento de demanda energética.
- No cubrimiento de localidades, comunidades o ciudades capaces de abarcar si se produjera la energía real instalada.

b) Económicos:

- Incremento en costos de mantenimiento (periódico, predictivo, correctivo, preventivo, cambios de componentes, etc.) dirigido a los aerogeneradores.
- Sobreutilización de los aerogeneradores.
- Costos altos de producción de energía por unidad (KW, MW, etc.)
- Retraso en la recuperación de la inversión del campo eólico.
- Los paros innecesarios de los aerogeneradores debido a factores de mantenimiento, cambio de componentes, restauración, etc. provocan una reducción considerable en el número de horas disponibles en un año, tiempo en el cual se planea que la(s) turbina(s) generen una cierta producción energética esperada (AEP, por sus siglas en ingles que significan: Producción Anual de Energía kWh/año*) por lo que esta

variable beneficio-costo señala la rentabilidad y factibilidad de todo proyecto, en especial de esta índole (Kusiak & Zong, 2009).

*Al maximizar la Producción Anual de Energía (AEP, kWh/año) simultáneamente se estará dando lugar a la oportunidad de reducir los costos de energía producida (Kusiak & Zong, 2009).

De esta manera nuestra mayor justificación al desarrollar el presente proyecto, es lograr la máxima eficiencia energética en distintos escenarios propuestos de campos eólicos, mediante un enfoque metaheurístico, el cual nos brinde una buena solución de diseño para la distribución óptima de aerogeneradores en un tiempo computacional razonable, garantizando la obtención de los mayores beneficios posibles en los ámbitos anteriormente mencionados (sociales y económicos).

Por consiguiente, haciendo referencia a lo anteriormente mencionado, el presente proyecto tiene una justificación de valoración y reconocimiento nacional, ya que se pretende que este trascienda y su utilice como herramienta para optimizar aquellos campos eólicos que se encuentran instalados en nuestro país o la instalación de futuros.

1.5 Alcances y limitaciones

1.5.1 Alcances

- Solamente se contempla la optimización de instancias de campos eólicos planos con dimensiones cuadradas y rectangulares donde el centro de cada una de las cuadrículas representa una posible localización para el aerogenerador.
- Para la optimización de un escenario de campo eólico se considera un solo tipo de aerogenerador; altura, producción de energía nominal, radio del rotor, etc. Es decir en el presente trabajo no se considera o analiza para la optimización el uso de aerogeneradores con diferentes propiedades técnicas.
- Se propone diseñar e implementar un método metaheurístico (Algoritmos Genéticos) que validado con el Diseño de Experimentos brinde soluciones de muy alta calidad en comparación a las soluciones de instancias reportadas en la literatura e incluso se pretende comparar las soluciones encontradas por el método metaheurístico con las soluciones encontradas por un método numérico no lineal; GRG non-linear, con la

finalidad determinar y analizar la cantidad de recurso computacional requerido por cada uno, así como la calidad de las soluciones.

- La presente investigación abarca la optimización de instancias o escenarios de campos eólicos hipotéticos reportados en la literatura. Asimismo el presente trabajo solamente se enfoca en la optimización de campos eólicos con dimensiones específicas y una cantidad de aerogeneradores predeterminada, asumiendo que el terreno es factible y viable para la construcción de un proyecto de campo eólico, es decir, la investigación no se centra en analizar el recurso potencial eólico sino se asume que el
- En esta investigación se consideran campo eólicos construidos en tierra y mar (a través del valor del coeficiente de rugosidad es posible determinar a qué tipo de campo eólico pertenece).

1.5.2 Limitaciones

- El equipo computacional para ejecutar las diferentes corridas de optimización.
- El tiempo para realizar la investigación.
- La oportunidad de aplicación en un campo eólico real.
- El acceso a datos reales para realizar una optimización.

Marco Teórico

Capítulo 2. Campos eólicos

2.1 Conceptos de diseño

El diseño es toda acción creadora que cumple su finalidad. Un acto creador es producir algo nuevo. Por lo tanto se subraya que “diseñar es un acto humano fundamental: diseñamos toda vez que hacemos algo por una razón definida” (Scott, 1951).

Morales (2004) define el diseño como la generación de estrategias y configuración de la forma de los objetos, entendida como uno de los más importantes mediadores del hombre con su cultura y medio ambiente. Sus objetivos y responsabilidades son:

- 1) Humanizar las soluciones técnicas que se dan a las necesidades de la sociedad, para así alcanzar mayores niveles en la calidad de vida de los usuarios, considerando las limitaciones y objetivos tecnológicos y comerciales.
- 2) Promover la sustentabilidad de la sociedad en términos de respeto y conservación del medio ambiente y sus recursos.

Munari (2008) clasifica desde una perspectiva proyectista el diseño en; visual, concerniente a imágenes comunicadoras: signos, señales, símbolos, significado de formas y colores, etc.; industrial, relativo a la proyección de objetos de uso y al estudio de medios y materiales; gráfico, relativo al mundo de la estampa, los libros impresos, etc. y de investigación, dedicado a la experimentación con estructuras y las posibilidades combinatorias de los materiales.

El diseño es el salto imaginativo desde la realidad presente a las posibilidades futuras. Asimismo, también conceptualiza el diseño de ingeniería como aquel determinado por factores tecnológicos altamente sofisticados (Asimow, 1962).

2.2 Energía

En el campo de la física, Walker (2009) define que el término de energía es tan amplio que es difícil escribir una definición clara. Técnicamente, la energía es una cantidad escalar asociada con el estado (o condición) de uno o más objetos. De forma más general, la energía es una cantidad que asociamos con un sistema de uno o más objetos. Si una fuerza cambia uno de los objetos, por ejemplo, haciendo que se mueva, entonces cambia la cantidad de energía.

De igual forma, el mismo autor mencionado anteriormente comenta que después de incontables experimentos, científicos e ingenieros se dieron cuenta que si se planea con todo cuidado el esquema por el que se asignan cantidades de energía, es posible usar estas

cantidades para predecir los resultados de experimentos y, lo que es más importante, para construir máquinas.

Por último, comenta que este éxito se basa en una maravillosa propiedad de nuestro universo: la energía se puede transformar de un tipo a otro y pasarse de un objeto a otro, pero la cantidad total es siempre la misma (la energía se conserva).

En el área de la electricidad, Nieves (2011) explica las diferencias entre: energía primaria, energía intermedia y energía final.

- a) La energía primaria es aquella que se encuentra disponible en la naturaleza, pudiendo agruparse en energía renovable y fósil. Entre las renovables podemos destacar la proveniente del Sol, el viento, del agua y de la biomasa. Entre las fósiles tendríamos el uranio, el carbón, petróleo y el gas natural. Para valorar la energía primaria renovable se tendrá en cuenta la energía producida y no la disponible pero no aprovechable por no existir potencia instalada que sea capaz de aprovechar esta energía proveniente de fuentes renovables.
- b) La energía intermedia es aquella que sufre las transformaciones necesarias para ser consumida. Son los denominados vectores energéticos entre los que destacamos electricidad y los combustibles (mediante tratamiento del petróleo en refinerías para producir gasolinas, gasóleos y gases licuados). También suelen utilizarse paneles solares para transformar la energía primaria del Sol en energía intermedia eléctrica.
- c) La energía final es aquella consumida en el hogar o la empresa, así como en los vehículos para el transporte de personas y mercancías. Esta energía tendría forma de calor, frío, luz y fuerza, agua caliente y desplazamientos de personas y mercancías.

2.3 Eficiencia energética

La presente sección del marco teórico se obtuvo completamente de Josep Balcells (2011).

A grandes rasgos, eficiencia energética se refiere a obtener el máximo rendimiento de la energía consumida y de las instalaciones necesarias para su generación, transporte y utilización, garantizando un funcionamiento sin interferencias de todos los receptores conectados a la red de distribución.

La electricidad tiene, como se sabe, un grave inconveniente con respecto a otros tipos de energía y es que no permite su almacenamiento en cantidades significativas, lo cual implica que hay que generarla y transportarla en el preciso momento de su utilización. Esto obliga a

dimensionar las instalaciones para prever la demanda máxima y por consiguiente la infrutilización de tales instalaciones en los momentos de menor demanda.

2.4 Energía eólica

La presente sección del marco teórico se obtuvo completamente de Antonio Aguilera Nieves (2011).

La energía eólica tiene origen en el movimiento de las masas de aire, es decir, en el viento. Este es una fuente de energía inagotable y disponible a nivel mundial y que, al igual que la mayoría de las fuentes de energía renovables, proviene del sol, ya que, son las diferencias de temperatura entre las distintas zonas geográficas de la Tierra y sus consecuentes diferenciales de presión, las causas que generan la circulación de aire.

De este modo, el fenómeno del viento está presente en todos los rincones de nuestro planeta, pero la mayor o menor potencialidad del mismo es lo que hace más o menos interesantes ciertos lugares para la obtención de energía con fuente eólica. En general, en las áreas costeras, las llanuras interiores abiertas, los valles transversales y las zonas montañosas es donde existe mayor potencial de viento.

2.5 Aerogeneradores

Esta sección del marco teórico se obtuvo completamente de Antonio Aguilera Nieves (2011).

Un aerogenerador es una máquina eléctrica, capaz de transformar energía mecánica en energía eléctrica, generando una corriente alterna mediante inducción electromagnética. Los alternadores están fundados en el principio de que, en un conductor sometido a un campo magnético variable, se crea una tensión eléctrica inducida cuya polaridad depende del sentido del campo y su valor del flujo que lo atraviesa. Al aerogenerador también se le llama alternador.

Un aerogenerador consta de dos partes fundamentales, el inductor, que es el que crea el campo magnético y el inducido que es el conductor el cual es atravesado por las líneas de fuerza de dicho campo magnético.

- a) Inductor: El rotor, que en estas máquinas coincide con el inductor, es el elemento giratorio del alternador, que recibe la fuerza mecánica de rotación.
- b) Inducido: En el inducido, es el estator y lo constituye una serie de pares de polos distribuidos de modo alterno y, en este caso, formados por bobinado en torno a un

núcleo de material ferromagnético de característica blanda, normalmente hierro dulce.

La rotación del inductor hace que su campo magnético, formado por imanes fijos, se haga variable en el tiempo, y el paso de este campo variable por los polos del inducido genera en él una corriente alterna que se recoge en los terminales de la máquina.

Las principales características de un aerogenerador que están vinculadas con la optimización del diseño de campos eólicos se presentan en la Tabla 2.1.

Tabla 2. 1 Principales características de los aerogeneradores y nomenclatura

Característica	Nomenclatura
Velocidad de arranque	c_i
Velocidad de paro	c_o
Diámetro del rotor	d
Altura del centro de generación de energía de la turbina	z
Velocidad nominal	-
Potencia nominal	-
Curva de potencia	-

Cuando un viento impacta sobre una turbina y la velocidad de este es mayor que c_i , las palas de las turbinas comienzan a girar y generar potencia (energía). La potencia que producida asciende al cubo a razón de la velocidad del viento hasta que la velocidad del viento alcanza la *velocidad nominal*, en dicho punto el sistema de control del aerogenerador ajusta el ritmo de las palas para que la potencia producida sea uniforme y equivalente a la *potencia nominal*. Cuando la velocidad del viento alcanza c_o , el aerogenerador automáticamente detiene su operación, debido a que al trabajar con una velocidad igual o mayor a esta velocidad genera daños en sus componentes eléctricos y/o mecánicos. Otra de las principales características importantes es la *curva de potencia*, la cual brinda la potencia producida en cada velocidad del viento comprendida entre c_i y c_o . La Figura 1.1 que se muestra en el primer capítulo, corresponde a un ejemplo de curva de potencia para un aerogenerador marca SENVION. Las características y nomenclaturas respectivas a este tipo de aerogenerador son: $c_i = 3$ m/s, $c_o = 22$ m/s, potencia nominal = 3,200 kW y velocidad

nominal = 12 m/s. La información de datos restantes de potencia para cada velocidad de viento se puede obtener interpolando.

2.5.1 Componentes principales de los aerogeneradores

a) Rotor eólico:

Es el conjunto de componentes giratorios del aerogenerador. Estos componentes son las palas, el buje y el mecanismo de cambio de paso de la pala.

b) Palas:

Conjunto de mecanismos giratorios cuya finalidad es captar la energía cinética del viento para hacer girar al rotor del generador.

c) Buje:

Es el elemento de unión de las palas con el sistema de rotación, los bujes se pueden clasificar de dos tipos; buje rígido y buje basculante. El buje rígido es un sistema en el cual la pala se atornilla al buje y este se fija rígidamente al eje de giro. Los bujes basculantes son una alternativa de los bujes rígidos para reducir las cargas que se producen. Estos bujes están conectados al tren de potencia a través de un apoyo que le permite balancearse libremente, por lo que permite pequeños movimientos en dirección perpendicular al rotor.

d) Mecanismo de cambio de paso de la pala:

La función del cambio de paso de pala es doble, por un lado permite controlar la potencia y velocidad de giro del rotor eólico, y por otra parte es capaz de parar aerodinámicamente al aerogenerador en caso de emergencia.

e) Sistemas de transmisión:

El sistema de transmisión o mejor conocido como tren de potencia, lo constituyen todos los elementos y componentes de la turbina que transmiten par mecánico al eje de giro. De acuerdo con esta definición, el sistema mecánico de transmisión, en una aeroturbina de eje horizontal, lo componen al menos el rotor eólico y el generador eléctrico.

f) Multiplicadora:

La función principal de este componente es multiplicar la velocidad de giro del eje secundario o de alta velocidad con respecto a la del eje primario. Un valor que caracteriza el diseño de

las multiplicadoras eólicas es la relación de multiplicación, que es el cociente entre la velocidad de giro rápido y el eje de giro lento.

g) Freno mecánico:

El propósito principal del freno mecánico es mantener bloqueado el eje de giro durante la operación de puesta en marcha y mantenimiento del aerogenerador. Cuando el freno mecánico se diseña únicamente para bloquear el rotor, el par que debe soportar es el transmitido por el rotor eólico con las palas en bandera y en condiciones de viento extremo.

h) Torre:

Es uno de los componentes principales de los aerogeneradores. Por lo tanto, es un elemento convencional del aerogenerador. Uno de los parámetros principales de la torre es su altura, la producción de energía de la turbina aumenta siempre directamente de acuerdo al perfil vertical de la velocidad del viento.

i) Mecanismo de orientación:

El mecanismo de orientación es el elemento o componente que se utiliza para hacer girar de manera automática el rotor eólico, de tal forma que la dirección del viento incidente sea lo más perpendicular posible al plano de giro de las palas. Este sistema de orientación permanece activo ya que utiliza motores eléctricos o sistemas hidráulicos para efectuar el movimiento del rotor, a diferencia de otros sistemas denominados pasivos, donde las propias fuerzas aerodinámicas realizan las funciones de orientación.

2.5.2 Tipos y clasificación de aerogeneradores

Existen muchos tipos y modelos diferentes de aerogeneradores empleados para el aprovechamiento del potencial eólico y transformarlo en energía eléctrica.

En cuanto a la disposición del eje de transmisión se puede dividir en:

- a) Aerogeneradores de eje vertical: Tienen la ventaja de que no necesitan ningún sistema de orientación y por la disposición del eje, posee el generador y los sistemas de control a nivel del suelo.
- b) Aerogeneradores de eje horizontal: Se caracterizan porque siempre hacen girar sus palas en dirección perpendicular a la velocidad del viento.

En la Figura 2.1 se muestra un aerogenerador de eje vertical. En dicha figura se puede apreciar que tanto el generador de energía y los sistemas eléctrico-electrónicos se encuentran a nivel del suelo.



Figura 2. 1 Aerogenerador de eje vertical. Fuente: Nieves (2011)

En la Figura 2.2 se muestra un aerogenerador de eje horizontal. En tal figura se aprecia que el estator se encuentra a cierta distancia con respecto al suelo. Dicha distancia depende considerablemente de la altura de la torre (estructura normalmente metálica).



Figura 2. 2 Aerogenerador de eje horizontal. Fuente: Nieves (2011)

También se pueden clasificar por el número de palas que contiene el aerogenerador. Así como por la posición de trabajo, si a barlovento o sotavento. Incluso por aerogeneradores de torre tubular y torre de celosía.

En la Figura 2.3 se presenta un aerogenerador tipo Barlovento. En dicha figura se puede apreciar como el diseño de este tipo de aerogenerador permite que el viento incidente choque en primera instancia con el campo de operación de las palas del aerogenerador debido a que el estator y las palas se encuentran ubicadas en dirección opuesta a la dirección del viento dominante.




Figura 2. 3 Aerogenerador tipo Barlovento. Fuente: Nieves (2011)

La Figura 2.4 muestra un aerogenerador tipo Sotavento. En tal figura se puede observar que, en este tipo de aerogenerador el viento incide sobre la parte trasera del estator y posteriormente incide sobre el área de operación de las palas. Por lo tanto, para este tipo de aerogeneradores tanto el estator y las palas se encuentran situados en la dirección del viento dominante.




Figura 2. 4 Aerogenerador tipo Sotavento. Fuente: Nieves (2011)

2.6 Campo eólico

La presente sección del marco teórico se obtuvo completamente de Antonio Aguilera Nieves (2011).

Recibe el nombre de campo eólico el conjunto de aerogeneradores, caminos, conductores de la electricidad, subestación transformada y demás instalaciones que hacen posible la producción de energía eléctrica aprovechando la acción del viento. Los campos eólicos se pueden situar en tierra o en el mar, siendo los primeros los más habituales, aunque los campos instalados en el mar han experimentado un crecimiento importante en Europa en los últimos años.

El número de aerogeneradores que componen un campo eólico es muy variable, y depende fundamentalmente de la superficie disponible y de las características del viento en el emplazamiento. Antes de montar un campo eólico se estudia el viento en el emplazamiento elegido durante un tiempo que suele ser superior a un año. Para ello se instalan veletas y anemómetros. Con los datos recogidos se traza una rosa de los vientos que indica las direcciones predominantes del viento y su velocidad.

Los campos eólicos proporcionan diferente cantidad de energía dependiendo de las diferencias sobre el diseño, situación de las turbinas, y por el hecho de que los antiguos

diseños de turbinas eran menos eficientes y capaces de adaptarse a los cambios de dirección y velocidad del viento.

De forma abreviada podemos afirmar que un campo eólico de generación eléctrica consiste en una serie de instalaciones que transforman la energía cinética del flujo del viento en energía eléctrica. Y, debido a las peculiares características de los vientos, de comportamiento irregular en su intensidad y dirección, el aprovechamiento de esta energía exige una tecnología compleja, con mecanismos de regulación orientación. En ello consisten los equipos más relevantes de un parque eólico, esto es, los aerogeneradores.

En la Figura 2.5 se puede apreciar la instalación de un campo eólico localizado en La venta, Oaxaca. Dicho campo eólico cuenta con un total de 87 aerogeneradores distribuidos en cuatro hileras paralelas. De igual forma se puede apreciar que las cuatro hileras paralelas se encuentran ubicadas respecto a la dirección dominante del viento.




Figura 2. 5 Campo eólico: La venta, Oaxaca. Fuente: (Google Maps, 2018).

2.7 Efecto estela

En un campo eólico, los aerogeneradores extraen energía cinética del viento para operar o producir energía, por lo que, el viento al pasar sobre una primera turbina sufrirá cierto déficit de velocidad, provocando una menor producción de energía en una segunda turbina instalada detrás de la primera. Dicho fenómeno de interferencia aerodinámica entre turbinas es llamado efecto estela. La modelación de este fenómeno ha sido causa de muchas investigaciones, por lo que han surgido diversos modelos para estudiar las características de este fenómeno (velocidad con la que se expande, diámetro del efecto, variaciones de la velocidad a cierta distancia, etc.).

De acuerdo con Shakoor *et.al* (2016) los modelos disponibles en la literatura se dividen en dos grupos principales: modelos cinemáticos y modelos de campo. Dentro de los Modelos Cinemáticos podemos encontrar el Modelo de Jensen, Modelo de Larsen y Modelo de Frandsen. De los modelos de campo, se encuentran: Eddy viscosity/ modelos de terreno de 2 dimensiones y modelos de campo de tres dimensiones.

Para el presente trabajo, se considera la utilización del modelo analítico de Jensen, el cual es propuesto por Samorani (2013), y el cual a su vez es un modelo equivalente al propuesto por Lackner & Elkinton (2007). Las ecuaciones para calcular los parámetros correspondientes al Modelo de Jensen se explican más adelante.

Asimismo, la consideración de la utilización de este modelo en el presente proyecto se justifica, debido a que se ha demostrado en diversos estudios que el modelo de Jensen es computacionalmente eficiente y presenta un alto grado de precisión para los fines establecidos.

El modelo consiste en un cono con una expansión lineal del diámetro del efecto estela y una disminución lineal del déficit de velocidad de viento dentro del efecto estela. Para una mejor explicación del modelo se muestra la Figura 2.6.




Figura 2. 6 Representación esquemática del efecto estela. Fuente: Elaboración propia.

En la Figura 2.6 se puede apreciar un viento incidente de izquierda a derecha a cierta velocidad U_0 e interactúa con una turbina (representada con un rectángulo en la parte izquierda de la figura): El radio del rotor de esta turbina es r_r . A una determinada distancia x de acuerdo a la misma dirección del viento, la velocidad del viento es U y el radio de la estela (inicialmente es r_r) se deduce como $r_1 = \alpha x + r_r$.

El escalar α determina que tan rápido se expande el efecto estela a medida que avanza en relación con la distancia y se denota como:

$$\alpha = \frac{0.5}{\ln \frac{z}{z_0}} \quad (2.1)$$

donde z es la altura del centro de generación de energía de la turbina que produce el efecto estela y z_0 es una constante conocida como rugosidad del terreno, que depende de las características de la superficie terrestre. Sea i la posición de la turbina que genera el efecto estela, j la posición afectada por la posición i , u_0 la velocidad del viento incidente puro (sin turbulencia), y u_j la velocidad del viento disponible en j . Entonces:

$$u_j = u_0(1 - vd_{ij}) \quad (2.2)$$

donde vd_{ij} es el *déficit de velocidad* inducida en la posición j por el efecto estela generado por i . por lo tanto vd_{ij} se calcula con la siguiente ecuación:

$$vd_{ij} = \frac{2a}{1 + \alpha \left(\frac{x_{ij}}{r_d}\right)^2} \quad (2.3)$$

El término a que aparece en el numerador es conocido como el *factor axial de inducción* y se calcula de la siguiente manera:

$$a = 0.5 \left(1 - \sqrt{1 - C_T}\right) \quad (2.4)$$

El término C_T es el coeficiente de empuje constante, el cual evalúa la proporción de energía capturada cuando el viento pasa a través de las aspas del aerogenerador. Los fabricantes de aerogeneradores normalmente brindan datos e información relacionados con el coeficiente de empuje.

El término r_d que se presenta en el denominador es llamado *radio del rotor corriente abajo* (radio del efecto estela corriente abajo) y se calcula con la siguiente expresión:

$$r_d = r_r \sqrt{\frac{1-a}{1-2a}} \quad (2.5)$$

El término x_{ij} es la distancia entre las posiciones i y j . Debido a que en la mayoría de los campos eólicos se instalan una gran cantidad de aerogeneradores, los efectos estelas pueden entrelazarse y acumularse. Estas acumulaciones de efectos estela pueden afectar a una o más turbinas corrientes abajo al mismo tiempo. En el modelo de Jensen, *el déficit de velocidad total* $v_{\text{def}(j)}$ en una posición j que es afectada por más efectos estela se obtiene con la siguiente expresión:

$$v_{\text{def}(j)} = \sqrt{\sum_{i \in W(j)} (vd_{ij})^2} \quad (2.6)$$

donde $W(j)$ es el conjunto de aerogeneradores que afectan a la posición j con un efecto estela.

Po lo tanto, $v_{\text{def}(j)}$ se sustituye en (2.3) en lugar de vd_{ij} para calcular u_j .

Capítulo 3. Optimización

3.1 Modelos de optimización

De acuerdo con Taha (2012) las fases principales para implementar la Investigación de Operaciones en la práctica son:

1. Definición del problema.
2. Construcción del modelo.
3. Solución del modelo.
4. Validación del modelo, lo cual incluye prueba y mejora del mismo.
5. Implementación de la solución.

Según Prawda (1982) en investigación de operaciones existen tres clases de modelos: icónicos, analógicos y simbólicos.

Los modelos icónicos son imágenes a escala del sistema cuyo problema se requiere resolver. Por ejemplo, las fotografías, las maquetas, dibujos y modelos a escala de barcos, automóviles, aviones, canales, etc., son modelos icónicos.

Los modelos analógicos se basan en la representación de las propiedades de un sistema cuyos problemas se requieren resolver utilizando otro sistema cuyas propiedades son equivalentes. Por ejemplo, las propiedades de un sistema hidráulico son equivalentes a las de un sistema eléctrico, o, inclusive, económico.

Los modelos simbólicos son conceptualizaciones abstractas del problema real a base del uso de letras, números, variables y ecuaciones. Este tipo de modelos son fáciles de manipular y se puede hacer con ellos un gran número de experimentos. De las tres clases de modelos, los simbólicos son los más económicos de construir y operar.

A pesar de la diversidad de los distintos tipos de modelos, todos tienen un aspecto en común, el cual corresponde a que un modelo es una abstracción minuciosamente seleccionada de la realidad, es decir un modelo es una simplificación del problema o situación real, con el objetivo de reducir su complejidad y con ello analizarlo de mejor forma para poder obtener una solución.

Hillier & Lieberman (2010) comentan que, una vez que el tomador de decisiones define el problema, el siguiente paso consiste en reformularlo de manera conveniente para su análisis. La forma convencional en que la Investigación de Operaciones logra este objetivo es mediante la construcción de un modelo matemático que represente la esencia del problema. Por lo tanto, los modelos matemáticos son representaciones que están expresados en términos

de símbolos y expresiones matemáticas. Dichos modelos son invaluable, debido a que extraen la esencia del material de estudio, muestran sus interrelaciones y facilitan el análisis. Asimismo, Hillier & Lieberman (2010) explican que, el modelo matemático de un problema industrial está conformado por el sistema de ecuaciones y expresiones matemáticas relacionadas que describen la esencia del problema. Para comprender de mejor manera, la estructura de un modelo matemático se muestra la Figura 3.1.

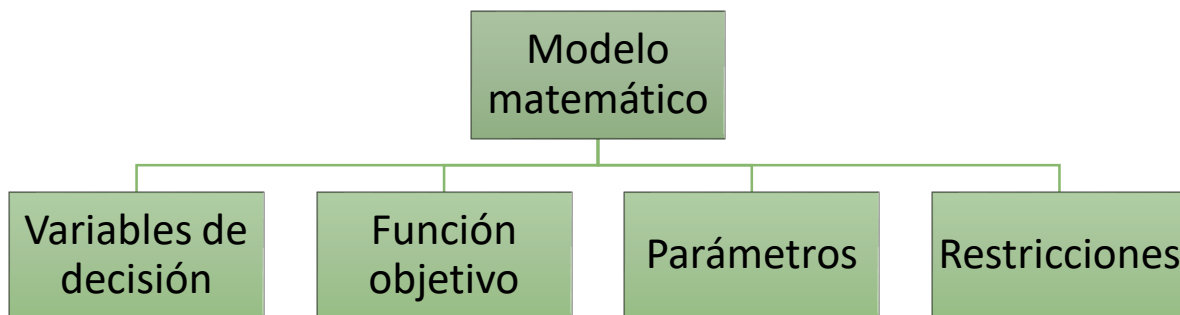


Figura 3. 1 Estructura de un modelo matemático

La Figura 3.1 muestra los elementos principales de un modelo matemático. Las variables de decisión (x_1, x_2, \dots, x_n) son las representaciones de las n decisiones que deben tomarse, las cuales son cuantificables y están relacionadas entre sí. A este conjunto de variables se les debe determinar los valores respectivos. La función objetivo corresponde a la medida de desempeño (por ejemplo, la ganancia), la cual debe ser adecuada al problema en análisis, y se expresa como una función matemática de las variables de decisión (por ejemplo, $3x_1 + 2x_2 + \dots + 5x_n$). Las restricciones son expresiones matemáticas que representan todas las limitaciones que se puedan imponer sobre los valores de las variables de decisión, casi siempre en forma de ecuaciones o desigualdades (por ejemplo, $x_1 + 3x_2 + 2x_3 \leq 10$).

Las constantes (los coeficientes o el lado derecho de las expresiones) de las restricciones y de la función objetivo se llaman parámetros del modelo.

Por lo tanto, Hillier & Lieberman (2010) comentan que, el modelo matemático puede decir entonces que el problema es elegir los valores de las variables de decisión de manera que se maximice la función objetivo, sujeta a las restricciones dadas.

No obstante, Eppen *et.al* (2000) comentan que los modelos más comúnmente utilizados por los gerentes son los modelos análogos en forma de cuadros y gráficas, pero también crean en

gran medida modelos simbólicos, por el hecho de que estos utilizan variables cuantitativamente definidas e interrelacionadas por medio de ecuaciones. Asimismo Eppen *et.al* (2000) comentan que los modelos simbólicos son también conocidos como modelos matemáticos o modelos cuantitativos.

De acuerdo a Taha (2012) la construcción de un modelo matemático, el cual es fundamental en la Investigación de Operaciones, implica un intento de transformar la definición del problema en relaciones matemáticas. Si el modelo resultante se ajusta a uno de los modelos matemáticos estándar, como la programación lineal, se suele obtener una solución utilizando los algoritmos disponibles. Por otra parte, si las relaciones matemáticas son demasiadas complejas como para permitir la determinación de una solución analítica, el equipo de Investigación de Operaciones puede optar por simplificar el modelo y utilizar un método heurístico, o bien considerar la simulación, si es lo apropiado.

Ackoff & Sasieni (1968) consideran los siguientes grados de dificultad en la construcción de modelos:

- a) Grado de dificultad 1. La estructura del sistema es sencilla de observar, analizar, entender y modelar a simple vista y/o como consecuencia de pláticas realizadas con el grupo de individuos que componen el sistema.
- b) Grado de dificultad 2. La estructura del sistema es más complicada de modelar y, por lo tanto, se requiere de un sistema análogo cuya modelación cae dentro del grado de dificultad anterior.
- c) Grado de dificultad 3. La estructura del sistema puede deducirse o aproximarse en base a un análisis de cierta información.
- d) Grado de dificultad 4. La estructura del sistema no se puede deducir, sino únicamente aproximar a base de pura experimentación.
- e) Grado de dificultad 5. La estructura del sistema no se puede deducir y, por lo tanto, se conceptualiza una estructura artificial.

Los modelos siempre deben ser menos complejos que el sistema real, de otra manera, para que quebrarse la cabeza con modelos si se puede trabajar con el sistema real en sí. Los sistemas que son muy complejos pueden representarse por una serie de submodelos, que unidos, representarían al modelo del sistema original (Prawda, 1982).

Dar solución a un modelo consiste en determinar los valores de las variables, las cuales corresponden a aquellas variables que podemos controlar (independientes) en el sistema con el propósito de optimizar, en caso de ser posible, o en caso de no serlo, mejorar la eficiencia y rendimiento del sistema, contemplando considerablemente los objetivos establecidos por el grupo de toma de decisiones.

Asimismo, Prawda (1982) comenta que el análisis matemático clásico se utiliza para obtener las soluciones a un modelo de Investigación de Operaciones, en forma deductiva. Cuando éstas no son posibles de obtener en forma deductiva, se utiliza el análisis numérico, a fin de resolver el modelo en forma inductiva. Existen métodos de solución de tipo iterativo que son aquellas que se aproximan a la solución, o bien, dan la solución exacta, en base a una serie de repeticiones de la misma regla analítica sobre los resultados de una repetición anterior. Existen métodos de simulación que imitan o emulan al sistema real, en base a un modelo matemático. La técnica de simulación es muy útil en la solución de problemas con riesgo e incertidumbre bajos.

3.2 Optimización

La optimización es una disciplina fundamental en campos de la ciencia tales como la Informática, la Inteligencia Artificial o la Investigación Operativa. En otras comunidades científicas, la definición de optimización se torna bastante impreciso, y se relaciona con la idea de "hacerlo mejor". Algunos involucrados en la investigación operativa, comentan que el concepto de optimización se concibe como *el proceso de intentar encontrar la mejor solución posible a un problema de optimización, generalmente en un tiempo limitado* (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

Se puede decir que un *problema de optimización* es simplemente un problema en el que hay varias (en general muchas) posibles soluciones y alguna forma clara de comparación entre ellas, de manera que este existe si y sólo si se dispone un conjunto de soluciones candidatas diferentes que pueden ser comparadas. Desde un punto de vista matemático, un problema de optimización P se puede formular como una 3-tupla $P = (f, SS, F)$, definida como sigue (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007):

$$P = \begin{cases} \text{opt} : f(x), & \text{Función objetivo} & (3.1) \\ x \in F \subset SS & \text{s. a.,} & \\ & \text{Restricciones} & (3.2) \end{cases}$$

En (3.1) f es la función a optimizar (maximizar o minimizar). En (3.2) F es el conjunto de soluciones factibles y SS es el espacio de soluciones.

Este tipo de problemas se pueden dividir de forma natural en dos categorías: aquellos en los que la solución está codificada mediante valores reales y aquellos cuyas soluciones están codificadas por valores enteros. Dentro de la segunda categoría se encuentran un tipo particular de problemas denominados *problemas de optimización combinatoria*.

3.2.1 Óptimo local y óptimo global

Hillier & Lieberman (2010) comentan que cuando se presenta un problema de programación no lineal difícil o función objetivo como la que se muestra en la Figura 3.2, la cual corresponde a:

$$\text{Maximizar } f(x) = 12x^5 - 975x^4 + 28\,000x^3 - 345\,000x^2 + 1\,800\,000x,$$

$$\text{Sujeto a: } 0 \leq x \leq 31$$

es probable identificar dos tipos de soluciones o valores óptimos que maximizan o minimizan la función según sea el caso. Para fines de maximización, un posible tipo de solución implica encontrar un máximo local (o máximos locales) y otro tipo en encontrar un máximo global. Para el objetivo de minimización, un posible tipo de solución implica encontrar un mínimo local (o múltiples mínimos locales, como en el presente caso) y otro tipo encontrar un mínimo global.

Como en el caso de la gráfica de la función objetivo anteriormente mencionada, cuyo propósito es maximización, entonces se estaría ejecutando un método de procedimiento de mejora local (véase sección 3.7) para identificar si la solución encontrada corresponde a un tipo de solución óptima local u óptima global, este tipo de procedimiento puede verse como un procedimiento de escalada de montaña que se mantiene en ascenso en la gráfica de la función objetivo hasta que, en esencia, alcanza la cumbre de la montaña. Un procedimiento de mejora local bien diseñado, por lo general convergiría hacia un *óptimo local* (una cumbre de montaña), pero se detendrá aun si este óptimo local no es un óptimo global (la cumbre más alta de la montaña). En la gráfica de la función objetivo que se muestra en la Figura 3.2, se identifican óptimos locales múltiples. En este caso, los puntos locales están en $x=5$, $x=20$

y $x=31$. Sin embargo, sólo $x=20$ es un óptimo global. Por lo tanto, el valor óptimo que maximiza globalmente la función considerando el intervalo factible $0 \leq x \leq 31$ es $x=20$.

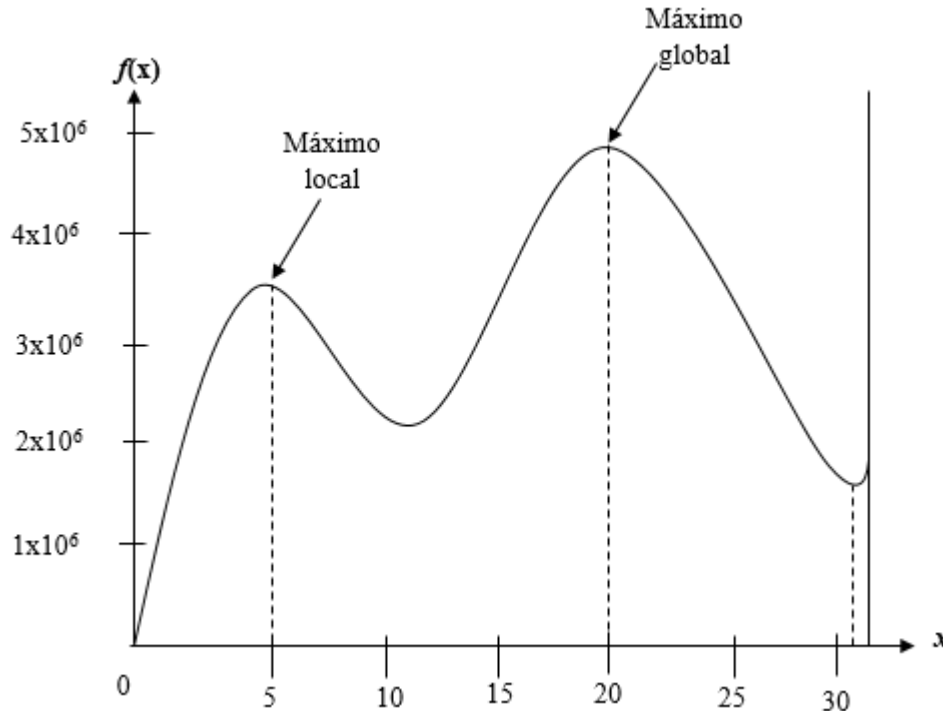


Figura 3. 2 Gráfica del valor de la función objetivo en un intervalo factible. Fuente: Elaboración propia.

3.2.2 Optimización combinatoria y problemas combinatorios

De acuerdo a Eppen *et.al* (2000) el término optimización combinatoria significa que existe sólo un número finito de alternativas factibles y que si todas ellas son enumeradas, será posible encontrar la óptima. El problema es que, en la práctica, ese número finito asciende muchas veces a millones o incluso a miles de millones de posibilidades, por lo cual la enumeración exhaustiva es del todo imposible aunque se utilicen computadoras de alta velocidad. Si bien es cierto que esos modelos se pueden formular como programas de números enteros con variables 0-1, muchas veces son tan grandes que aun con la formulación de PE resulta prohibitivo tratar de optimizarlos mediante los procedimientos habituales.

Un problema de optimización combinatoria consiste en encontrar un objeto entre un conjunto finito (o al menos contable) de posibilidades. Este objeto suele ser un número natural (o conjunto de naturales), una permutación o una estructura de grafo (subgrafo).

Algunos ejemplos muy conocidos de problemas de optimización combinatoria son el problema del viajante de comercio o del agente viajero (TSP, por sus siglas en inglés, *Travelling Salesman Problem*), el problema de la asignación cuadrática (QAP, por sus siglas en inglés, *Quadratic Assignment Problems*), los problemas de planificación (Scheduling Problems) o los problemas de cortes sobre grafos (*Cut Set Problems*) (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

Los problemas pertenecientes a la clase P tienen la característica que siempre existe un algoritmo con complejidad polinómica o exacto (por ejemplo, métodos como: algoritmos voraces, algoritmos de divide y vencerás, algoritmos de ramificación y corte, backtracking, programación dinámica, etc.) que permite obtener la solución óptima y en tiempo razonable. Este método consiste en la búsqueda exhaustiva del conjunto de soluciones (enumeración). Tal algoritmo suele ser ineficiente debido a que para la mayoría de los problemas prácticos y de ingeniería que se pueden encontrar en el tema de la optimización combinatoria el tiempo requerido para obtener una solución crece de forma exponencial a medida que se involucran más variables o se aumenta el tamaño del problema. Por lo tanto, este tipo de problemas se caracterizan por tener espacios de soluciones de gran tamaño (cardinalidad), es decir el tamaño del espacio de soluciones es muy elevado.

Desde finales de los años 70 se han intentado caracterizar matemáticamente los problemas combinatorios. De estos estudios se concluye que existe un subconjunto de problemas cuyos algoritmos de resolución presentan una complejidad computacional polinómica, es decir, el tiempo de ejecución de estos algoritmos crece de forma polinómica con el tamaño del problema. Este tipo de problemas se dice que pertenecen a la clase P y se considera que son resolubles de manera eficiente. Sin embargo, para la mayoría de problemas que tienen interés práctico o científico, no se conoce un algoritmo con complejidad polinómica que los resuelva de manera exacta. Este tipo de problemas pertenecen a una clase conocida como NP (nondeterministic polynomial time, por sus siglas en inglés). Dado el interés práctico que tiene la resolución de muchos problemas pertenecientes a la clase NP y la dificultad que existe en resolver dichos problemas de forma exacta, se plantea la opción de encontrar soluciones de alta calidad en tiempos razonables, aunque estas soluciones no sean óptimas. Para esta tarea se necesita utilizar algoritmos aproximados que permitan resolver los problemas combinatorios (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

3.3 Complejidad computacional

De acuerdo a Muñoz *et.al* (2007) se dice que un problema se puede resolver en un tiempo polinómico cuando el tiempo de ejecución de un algoritmo que lo resuelve se puede relacionar con el tamaño de la entrada (número de variables) con una formula polinómica.

La teoría de la complejidad computacional es una rama de la teoría de la computación, que se concentra en la clasificación de los problemas computacionales de acuerdo a la naturaleza de su dificultad y en la relación entre las clases de complejidad. Un problema se puede catalogar como “naturalmente difícil” si su solución requiere una gran cantidad de recursos computacionales, sin importar el algoritmo que se haya utilizado. La teoría de la complejidad computacional hace oficial dicha afirmación mediante modelos de cómputo matemáticos para el análisis de estos problemas y la cuantificación de la cantidad de recursos necesarios para resolverlos, como tiempo y memoria. Estos dos últimos corresponden a los recursos comúnmente estudiados en complejidad computacional, los dos recursos se explican como sigue:

- Tiempo: ¿Cuántos pasos son necesarios para resolver un problema?
- Espacio: ¿Cuánta memoria es necesaria para resolver un problema?

El propósito principal de la complejidad computacional es determinar los límites prácticos de lo que se puede realizar en una computadora y lo que no es posible realizar en la misma. Otro campo relacionado con la complejidad computacional es el análisis de algoritmos. La diferencia entre análisis de algoritmos y complejidad computacional, es que el primero se dedica a especificar la cantidad de recursos requeridos por un algoritmo en particular para resolver un problema, mientras que el segundo, analiza todos los posibles algoritmos que pudieran ser utilizados para resolver el mismo problema.

Por lo tanto, la complejidad computacional pretende clasificar los problemas que pueden, o no pueden ser solucionados con una cantidad específica de recursos.

Para explicar de manera ilustrativa el concepto y función de la complejidad computacional en la resolución de problemas se muestra la Figura 3.3. Dicha figura muestra un diagrama en el que dos algoritmos distintos son utilizados para resolver el mismo problema, cada uno de ellos presenta un crecimiento o comportamiento diferente, por lo que eso causa que la

cantidad de recurso (tiempo) empleado no sea la misma. Al resolver un problema mediante un algoritmo en particular (B), lo ideal y deseable es que este contenga una función con comportamiento o crecimiento polinómico a medida que el número de variables se incrementa, es decir que solucione el problema en un tiempo polinómico. En contraste a lo anterior, lo indeseable es que al resolver el mismo problema utilizando otro algoritmo (A), este contenga una función cuyo comportamiento o crecimiento sea diferente al polinomial, por ejemplo, comportamiento logarítmico, exponencial, factorial, etc. En tal situación, la complejidad computacional es la clave para analizar los posibles algoritmos (y la cantidad de recursos que estos implican) que pudieran ser utilizados para resolver el mismo problema. En adición, cabe comentar que los científicos de la computación distinguen los algoritmos de tiempo polinómico y los algoritmos de tiempo exponencial, declarando que los algoritmos de tiempo polinomial son “suficientemente eficientes” y los algoritmos de tiempo exponencial son “muy ineficientes” para resolver cierto problema. En este sentido, algoritmo “eficiente” se traduce “al más rápido”, así como involucra a todos los recursos computacionales necesarios para la ejecución de un algoritmo, siendo el recurso más importante el tiempo.

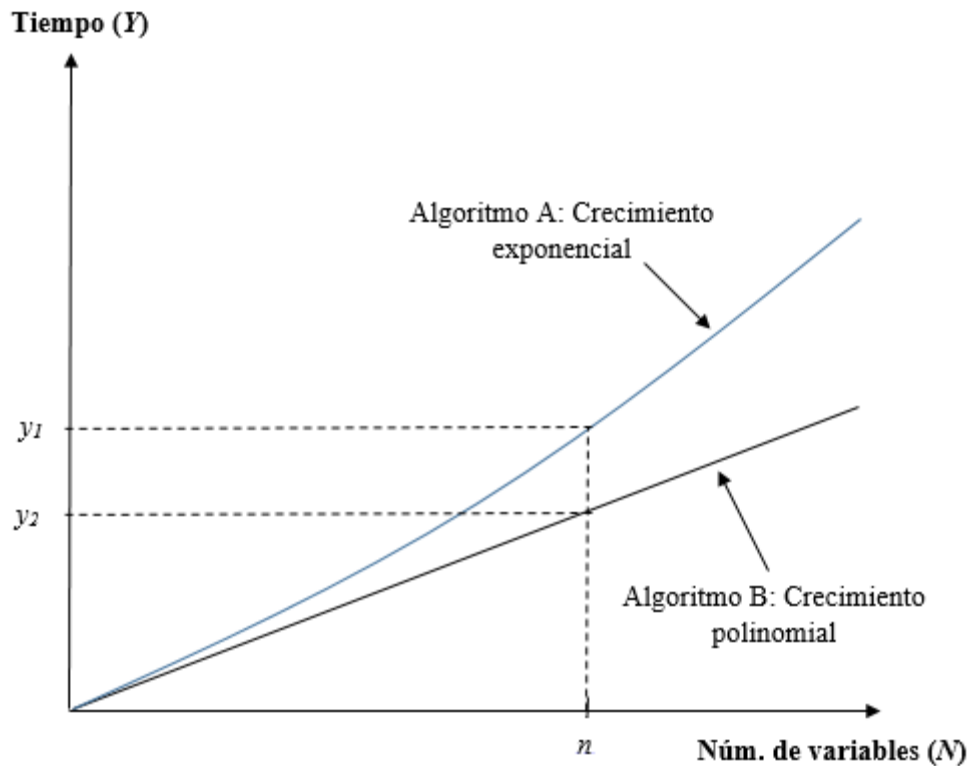


Figura 3. 3 Diagrama de complejidad computacional. Comparación de crecimiento entre dos algoritmos. Fuente: Elaboración propia.

Como bien se comentó anteriormente, los problemas se pueden clasificar en clases de complejidad de acuerdo a su naturaleza de dificultad para ser resueltos por una computadora, entre las clases destacan los problemas pertenecientes a: P, NP, NP-completos y NP-duros. En la siguiente sección se explican detalladamente estas clases de problemas.

3.4 Problemas P, NP, NP-completos y NP-duros

De acuerdo a Muñoz *et.al* (2007) matemáticamente, los problemas pueden caracterizarse de acuerdo a la dificultad que conlleva su resolución por un ordenador. Se han definido varias clases de problemas, entre las que destacan las clases *P*, *NP*, *NP-completo* y *NP-duro*.

Por lo tanto, Muñoz *et.al* (2007) considera que los problemas para los que existe un algoritmo polinómico que pueda resolverlos en un tiempo de ejecución razonable para la informática actual se denominan problemas *P*.

Asimismo, se puede decir que para un problema de tipo *NP* no se puede obtener una solución en un tiempo razonable hasta que exista un algoritmo polinómico que lo resuelva bajo esa circunstancia. A pesar de que para este tipo de problemas (*NP*) no se ha encontrado un

algoritmo polinómico que los resuelva, sí que se puede saber en tiempo polinómico si un valor corresponde a la solución del problema. Por ejemplo, el cálculo de la raíz cuadrada de un número puede ser un problema complicado. En cambio, conocer si un determinado valor es la raíz cuadrada de otro es bastante sencillo, ya que basta con elevar ese número al cuadrado. A simple vista, puede parecer que la gran mayoría de los problemas son *NP*, ya que intuitivamente parece que comprobar una solución es bastante más sencillo que calcularla. Sin embargo, para los problemas de optimización, comprobar si esos valores corresponden a la *solución óptima* no es nada sencillo. Los problemas *P* también son problemas *NP*, ya que siempre es posible comprobar que un valor es solución al problema en tiempo polinómico. Por lo tanto, el conjunto de problemas *P* es un subconjunto de los problemas *NP*.

Existe una relación entre las clases de complejidad *P* y *NP* que aún no ha podido ser resuelta o comprobada. Esta relación conlleva a la pregunta: ¿es $P = NP$?, la cual se traduce a: si es posible verificar en un tiempo polinómico soluciones positivas a un problema, ¿entonces también se pueden obtener las soluciones en un tiempo polinómico (es decir, que exista un algoritmo polinómico que resuelva los problemas *NP*)? (De hecho, si alguien es capaz de contestar dicha pregunta y demostrarlo matemáticamente, el Instituto Clay de Matemáticas (Cambridge-Massachusetts) le pagaría un millón de dólares.)

Por otro lado, existe otro tipo de problemas, llamados *NP-completos* que no tienen un algoritmo que los pueda resolver en tiempo polinómico. No se ha podido demostrar formalmente que no exista, pero los matemáticos creen que realmente no existen (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007). Los problemas *NP-completos* son un subconjunto de los problemas *NP*, es decir existe un algoritmo polinómico que puede determinar si un valor es solución al problema.

En adición, de acuerdo a Muñoz *et.al* (2007) para saber si un problema es *NP-completo*, al menos un problemas *NP-completo* tiene que ser reducible a ese problema. Se dice que un problema *A*, que es *NP-completo* es reducible a otro problema *B*, cuando se puede crear un algoritmo que resuelva el problema *A* utilizando como una caja negra un algoritmo para resolver el problema *B*. Es decir, existe un algoritmo para resolver *A* de la siguiente forma:

- Toma los datos de entrada del problema A , los transforma de manera que puedan utilizarse como entrada de una caja negra que resuelve el problema B , y la solución a B se pueda transformar a su vez en una solución para el problema A .
- La caja negra que resuelve el problema B puede utilizarse una única vez o un número polinómico de veces dentro del algoritmo que resuelve A .

Considerando que la caja negra que resuelve B se ejecuta en un único paso, el algoritmo para resolver A debe ser polinómico. Todos los problemas NP -completos son reducibles entre sí. Es decir, para resolver cualquier problema NP -completo se puede construir un algoritmo polinómico que use una caja negra que, a su vez, resuelve otro problema NP -completo, en caso de que esta caja negra se ejecutase en un único paso.

Por último, existen otro tipo de problemas al menos tan difíciles de resolver como los problemas NP -completos, aunque es posible que sean incluso más difíciles. A este tipo de problemas se les denomina NP -duros. Los problemas NP -duros no son un subconjunto de los problemas NP . Es decir, para los problemas NP -duros no existe un algoritmo polinómico que nos permita verificar una solución. Para que un problema sea considerado NP -duro, debe existir un problema NP -completo que sea reducible a este problema. Es decir, debe existir algún algoritmo polinómico que pueda usar una caja negra que resuelva el problema NP -duro para resolver un problema NP -completo. Se dice que este tipo de problemas son, al menos, tan difíciles de resolver como un problema NP -completo porque un algoritmo los podría utilizar para resolver un problema NP -completo. En resumen, rigurosamente hablando, las clases P y NP no están compuestas por los problemas de optimización, sino por sus correspondientes problemas de decisión.

La Figura 3.4 muestra la relación resumida entre las clases de problemas descritos anteriormente.




Figura 3. 4 Diagrama de relación entre las clases de problemas P , NP , NP -completos y NP -duros, para el caso en que $P \neq NP$. Fuente: Elaboración propia.

3.5 Programación entera

De acuerdo a Taha (2012) las aplicaciones de programación lineal entera (PLE por sus siglas en español) caen principalmente en dos categorías: *directa* y *transformada*. En la categoría *directa*, la naturaleza de la situación impide la asignación de valores fraccionarios a las variables del modelo. Por ejemplo, el problema puede implicar la determinación de si se emprende o no un proyecto (variable binaria), o la determinación del número óptimo de máquinas necesarias para realizar una tarea (variable general entera).

En la categoría *transformada* se utilizan variables enteras auxiliares para convertir analíticamente situaciones insolubles en modelos que pueden resolverse por medio de algoritmos de optimización disponibles. Por ejemplo, en la secuencia de dos trabajos, A y B, en una sola máquina, el trabajo A puede preceder al trabajo B o viceversa. La naturaleza “o” de las restricciones es lo que hace al problema analíticamente insoluble, porque todos los algoritmos de programación matemáticos tratan con solo restricciones “y”.

En la rama concerniente a la investigación operativa se han estudiado muchos ejemplos de aplicaciones distintas de la programación lineal. Sin embargo, una limitación importante que impide muchas otras aplicaciones es el supuesto de divisibilidad, el cual requiere que las variables de decisión puedan tomar cualquier valor, incluso valores no enteros, satisfaciendo las restricciones funcionales y de no negatividad (Hillier & Lieberman, 2010). Por lo tanto, Hillier & Lieberman (2010) comentan que en muchos problemas prácticos, las variables de decisión sólo tienen sentido real si su valor es entero. Por ejemplo, con frecuencia es necesario asignar a las actividades cantidades enteras de personas, máquina o vehículos. Asimismo, muchas de las numerosas aplicaciones importantes que involucran la

programación entera son aquellos problemas que incluyen cierto número de “decisiones tipo: sí o no”. En este tipo de problemas, las únicas dos elecciones posibles son *sí* o *no*. Por ejemplo, ¿Debe emprenderse un proyecto específico?, ¿Debe hacerse cierta inversión fija? ¿Debe localizarse una instalación en un sitio en particular? Debido a que este tipo de problemas involucran sólo dos viabilidades, este tipo de decisiones se pueden representar mediante variables de decisión restringidas a sólo dos valores. Este tipo de variables son llamadas variables binarias (o variables 0-1).

3.6 Heurísticas

De acuerdo a Muñoz *et.al* (2007) para la mayoría de problemas de interés no se conoce un algoritmo exacto con complejidad polinómica que encuentre la solución óptima a dicho problema. Además, la cardinalidad del espacio de búsqueda suele ser enorme, lo cual hace generalmente inviable el uso de algoritmos exactos, fundamentalmente porque la cantidad de tiempo que se necesitaría para encontrar una solución es completamente inaceptable. Por lo anterior, es recomendable la utilización de métodos aproximados o heurísticas que permitan obtener una solución de calidad en un tiempo razonable a estos problemas.

La heurística está diseñada para obtener buenas soluciones aproximadas de problemas combinatorios NP-Hard (difíciles), los cuales no pueden resolverse a través de los algoritmos exactos de optimización.

Una heurística es una técnica de búsqueda directa que utiliza reglas prácticas para localizar mejores soluciones (Taha, 2012). La ventaja primordial de la heurística es que brinda buenas soluciones con rapidez, utilizando reglas de solución sencillas. La desventaja de la heurística es que no brinda la solución óptima del problema sino una solución aproximada (esto es porque no hay forma de verificar con certeza que la solución encontrada tras la implementación de la heurística sea la óptima, es decir no se presentan condiciones de optimalidad que comprueben que la solución obtenida sea la óptima), por lo tanto, la calidad de la solución en comparación con la óptima se desconoce.

De acuerdo a Hillier & Lieberman (2010) existen algoritmos que pueden usarse para obtener una solución óptima para varios tipos de modelos de Investigación de Operaciones, entre los cuales se incluyen ciertas clases de modelos de programación lineal, programación entera y programación no lineal. Estos algoritmos han probado ser inaceptables para abordar una

amplia variedad de problemas prácticos debido a que algunos problemas pueden ser tan complicados que no es posible resolverlos y obtener una solución óptima en un tiempo computacional razonable, por lo que lo deseable e importante es solucionar dicho problema encontrando una buena solución factible en un tiempo computacional aceptable y que al menos éste razonablemente cerca de ser óptima. Por lo general, para buscar esa solución se utilizan métodos heurísticos.

El término *heurística* proviene del vocablo griego *heuriskein* que podría traducirse como: *encontrar, descubrir o hallar* (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

El concepto que aparece en el Diccionario de la Real Academia de la Lengua Española (DRAE) en su segunda y cuarta acepción es la que se presenta a continuación:

- Técnica de la indagación y del descubrimiento.
- En algunas ciencias, manera de buscar la solución de un problema mediante métodos no rigurosos, como por tanteo, reglas empíricas, etc.

Por otro lado, la Enciclopedia Salvat, considera la siguiente definición de Heurística:

“Arte de inventar o descubrir hechos valiéndose de hipótesis o principios que, aun no siendo verdaderos, estimulan la investigación”.

La heurística es una regla empírica intuitivamente atractiva para manejar un aspecto determinado de un modelo. Una colección de heurística, o algoritmos heurísticos se conoce como un programa heurístico. Por ejemplo, algunos programas de computadora para resolver problemas lineales (como Solver de Excel) aplican la heurística en la fase inicial del método simplex como un intento por encontrar con rapidez un vértice inicial. En términos generales, desde el punto de vista de un administrador, un procedimiento heurístico puede ser sin duda alguna tan aceptable como un algoritmo “más exacto” que produzca una solución óptima, y tal vez incluso preferible a éste en términos de costos (Eppen, Gould, Schmidt, Moore, & Weatherford, 2000).

Desde un punto de vista científico, el término heurística se debe al matemático G. Polya quien lo empleó por primera vez en su libro *How to solve it*. Con este término Polya quería expresar las reglas con las que los humanos gestionan el conocimiento común (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007). Actualmente, existen bastantes definiciones para el término heurística. Una de las más claras e intuitivas presentadas en la literatura es la que se presenta a continuación:

“Procedimientos simples, a menudo basados en el sentido común, que se supone que obtendrán una buena solución (no necesariamente óptima) a problemas difíciles de un modo sencillo y rápido” (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

Un método heurístico es un procedimiento que trata de describir una solución factible muy buena, pero no necesariamente una solución óptima, para el problema específico bajo consideración (Hillier & Lieberman, 2010). De igual forma, Hillier & Lieberman (2010) comentan que al utilizar un método heurístico no se garantiza la calidad de la solución que se obtiene, pero un método heurístico bien diseñado puede proporcionar una solución que al menos está cerca de ser óptima. El procedimiento también debe ser suficientemente eficiente como para manejar problemas muy grandes. Con frecuencia, el procedimiento es un *algoritmo iterativo novedoso*, donde cada iteración implica la realización de una búsqueda de una nueva solución que puede ser mejor que la solución que se encontró con anterioridad. Por lo tanto, cuando el algoritmo termina después de un tiempo razonable, la solución que proporciona es la mejor que se pudo encontrar en cualquier iteración.

Con frecuencia los métodos heurísticos se basan en ideas bastantes simples, de sentido común, acerca de la forma en que se debe buscar una buena solución. Estas ideas deben ajustarse al problema específico de interés. En consecuencia, los métodos heurísticos tienden a ser *ad hoc* por naturaleza. Es decir, por lo general cada método se diseña para abordar un tipo específico de problema en vez de una variedad de aplicaciones (Hillier & Lieberman, 2010).

De acuerdo a Eppen *et.al* (2000) en ocasiones, el modelo utilizado por un administrador puede llegar a ser tan complejo, que el modelo matemático no puede ser resuelto mediante los algoritmos exactos, debido a que el modelo formulado es demasiado grande, no lineal o demasiado complejo en el hecho que requiere el empleo de muchas variables 0-1 en su formulación. Asimismo otro motivo por el cual ciertos modelos no pueden ser solucionados por algoritmos exactos es porque las simplificaciones que se podrían aplicar al modelo complejo con la intención de hacerlo más accesible, desintegraría demasiados componentes de la estructura del modelo que son importantes en el mundo real (es decir, el modelo se alejaría tanto de la realidad, que dejaría de ser apropiado para su utilización).

Por lo tanto, Eppen *et.al* (2000) comentan que para obtener la solución óptima de un modelo bajo las circunstancias anteriormente descritas resulta demasiado difícil, demasiado laborioso

o quizá hasta imposible de encontrarla con los conocimientos y la tecnología actuales, por lo que en estos casos se puede aplicar un algoritmo heurístico. Un algoritmo heurístico es el que proporciona en forma eficiente soluciones aproximadas satisfactorias para un modelo determinado. Asimismo, cuando se emplea este tipo de algoritmos es posible medir con precisión qué tan “buena” es la aproximación obtenida. Por ejemplo, en optimización cuando se utilizan determinados algoritmos heurísticos, se puede declarar: “Al terminar el proceso podrá tener seguridad de contar con ____% de optimalidad” o bien, puede declararse que: “En ciertas suposiciones, la respuesta heurística será óptima en ____% de las ocasiones.” De igual forma Eppen *et.al* (2000) explica que los algoritmos heurísticos nunca proporcionan una solución “mala”, ya que es preferible contar en forma sistemática con soluciones razonablemente buenas, que obtener a veces la mejor solución y, de vez en cuando, una mala solución.

Los métodos heurísticos tienen su principal limitación en su incapacidad para escapar de óptimos locales. Esto se debe, fundamentalmente, a que estos algoritmos no utilizan ningún mecanismo que les permita proseguir la búsqueda del óptimo en el caso de quedar atrapados en un óptimo local. Para solventar este problema, se introducen otros algoritmos de búsqueda denominados metaheurísticas, que evitan en la medida de lo posible, este problema. Este tipo de algoritmos son procedimientos de alto nivel que guían a métodos heurísticos conocidos, evitando que estos queden atrapados en óptimos locales (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

3.7 Metaheurísticas

El término *Metaheurística* o *Meta-heurística* fue acuñado por F. Glover en el año 1986. Etimológicamente, deriva de la composición de dos palabras con origen griego, que son “meta” y “heurística”. El segundo término ha sido descrito en la sección anterior, mientras que el prefijo meta (en inglés) se podría traducir como *más allá de, en un nivel superior*. Con este término, Glover pretendía definir un procedimiento maestro de alto nivel que guía y modifica otras heurísticas para explorar soluciones más allá de la simple optimalidad local (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007).

De acuerdo a Taha (2012) las primeras generaciones de heurística se basan en la regla de búsqueda codiciosa (búsqueda local; proceso iterativo que inicia en un punto factible aleatorio y luego intenta moverse a un punto de mejor solución en la vecindad) que dicta que

se mejore el valor de la función objetivo con cada movimiento de búsqueda. La búsqueda termina en un óptimo local donde ya no son posibles más mejoras. En la década de 1980, una nueva generación de metaheurísticas buscó mejorar la calidad de las soluciones heurísticas al permitir la búsqueda de una trampa de escape en óptimos locales.

Una de las definiciones de *metaheurística* mejor descrita en la literatura es la presentada por J.P. Kelly *et al.* (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007):

“Las metaheurísticas son una clase de métodos aproximados que están diseñados para resolver problemas difíciles de optimización combinatoria en los que los heurísticos clásicos no son efectivos. Las metaheurísticas proporcionan un marco general para crear nuevos algoritmos híbridos combinando diferentes conceptos derivados de la inteligencia artificial, la evolución biológica y los mecanismos estadísticos”.

La evolución de las metaheurísticas durante los últimos 25 años ha tenido un comportamiento prácticamente exponencial. Desde las primeras reticencias por su supuesta falta de rigor científico hasta la actualidad, se ha resuelto una gran cantidad de problemas que inicialmente parecían inabordables.

De acuerdo con Hillier & Lieberman (2010) una metaheurística es un método de solución general que proporciona tanto una estructura general como criterios estratégicos para desarrollar un método heurístico específico que se ajuste a un tipo particular de problema. Por lo tanto, en síntesis, la metaheurística es un tipo general de método de solución que organiza la interacción entre los procedimientos de mejora local (véase Figura 3.5) y las estrategias de más alto nivel para crear un proceso que sea capaz de escapar de un óptimo local y realizar una búsqueda vigorosa de una región factible.

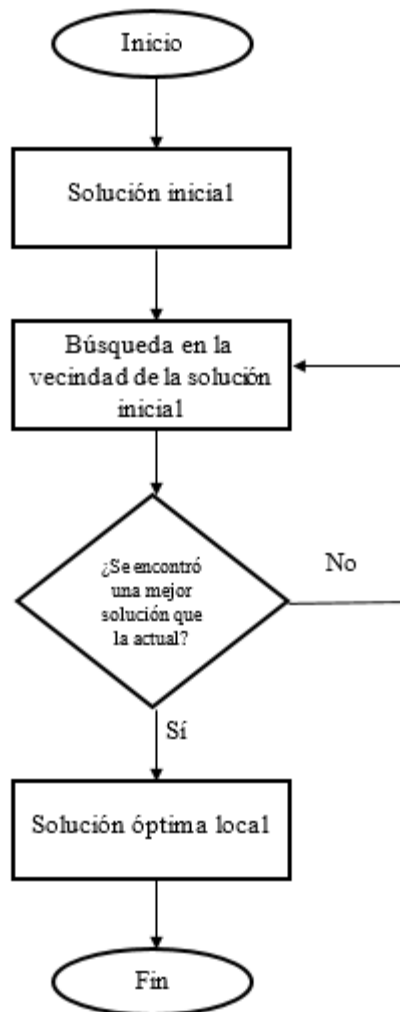


Figura 3. 5 Diagrama del procedimiento de mejora local. Fuente: Elaboración propia.

Las metaheurísticas están diseñadas principalmente para escapar del entrapamiento en el óptimo local al permitir movimientos inferiores (es decir explorar óptimos locales para poder brincar a al óptimo global), si es necesario. Se espera que la flexibilidad agregada a la búsqueda conduzca a una mejor solución. A diferencia de la heurística codiciosa, la cual siempre termina cuando se llega a un óptimo local, la terminación de una búsqueda metaheurística se basa en los siguientes puntos de referencia (Taha, 2012):

1. La cantidad de iteraciones de búsqueda excede una cantidad especificada.
2. La cantidad de iteraciones desde la última mejor solución excede una cantidad especificada.
3. La vecindad asociada con el punto de búsqueda actual, o está vacía o no puede conducir a un nuevo movimiento de búsqueda viable.

4. La calidad de la mejor solución actual es aceptable.

Una característica clave de la metaheurística es la capacidad de escapar de un óptimo local. Después de encontrar (o casi encontrar) un óptimo local, las diferentes metaheurísticas ejecutan este escape de modos diferentes. Sin embargo, una característica común es que las soluciones de prueba que de inmediato siguen un óptimo local pueden ser menores que éste (Hillier & Lieberman, 2010).

Asimismo, Hillier & Lieberman (2010) explican brevemente la ventaja y desventaja de una metaheurística. La ventaja es que tiende a moverse relativamente rápido hacia soluciones muy buenas, por lo que proporciona una forma muy eficiente de abordar problemas grandes y complicados. La desventaja es que no existe garantía de que la mejor solución que se encuentre sea una solución óptima o incluso que esté cerca de serlo. Por lo tanto, siempre que sea posible resolver un problema mediante un algoritmo que pueda garantizar optimalidad, debe usarse éste en lugar de la metaheurística, debido a que el papel de las metaheurísticas es abordar problemas que son muy grandes y complicados como para resolverlos por medio de algoritmos exactos. Por consiguiente, aunque algunas veces se aplican metaheurísticas a problemas difíciles de programación no lineal y entera, un área de aplicación más común es la de los problemas de *optimización combinatoria*.

Las metaheurísticas incluyen (pero no están restringidas a): métodos tan populares como optimización por colonias de hormigas (ACO, por sus siglas en inglés), algoritmos evolutivos (EA, por sus siglas en inglés), donde se incluyen los algoritmos genéticos (GA, por sus siglas en inglés) y los algoritmos meméticos (MA, por sus siglas en inglés), procedimientos de búsqueda miope (constructiva, voraz o ávida), aleatorizados y adaptativos (GRASP, por sus siglas en inglés), búsqueda local iterativa (ILS, por sus siglas en inglés), re-encadenamiento de trayectorias (PR, por sus siglas en inglés), recocido simulado (SA, por sus siglas en inglés), búsqueda dispersa (SS, por sus siglas en inglés) y búsqueda tabú (TS, por sus siglas en inglés) (Muñoz, Pantrigo Fernández, & Gallego Carrillo, 2007). Las metaheurísticas se clasifican en la literatura principalmente de acuerdo a su estrategia de búsqueda, entre las cuales podemos encontrar las metaheurísticas evolutivas o basadas en poblaciones (algoritmos evolutivos), metaheurísticas de búsqueda local o basadas en trayectoria (búsqueda tabú, templado simulado y búsqueda local iterativa) y metaheurísticas

constructivas (optimización basada en colonia de hormigas y GRASP, por sus siglas en inglés).

3.7.1 Metaheurísticas evolutivas y algoritmos genéticos

Diversos problemas de optimización que se presentan en el ámbito de la práctica e ingeniería suelen ser altamente irresolubles (por su alta dimensionalidad, multimodalidad, fuerte no linealidad y no diferenciabilidad) o muy difíciles de solucionar por medio de algoritmos exactos o técnicas exactas, por lo que resulta necesario recurrir a la aplicación de algoritmos evolutivos, inspirados en la naturaleza, los cuales integran un conjunto de modelos basados en la evolución de los seres vivos.

Los algoritmos evolutivos están diseñados para generar poblaciones de soluciones. Estos algoritmos se basan en generar, seleccionar, combinar y reemplazar un conjunto de soluciones. A comparación de los algoritmos clásicos de optimización basados en trayectorias, los algoritmos evolutivos en cada iteración no obtienen una única solución sino un conjunto de estas.

En síntesis, el concepto algoritmo evolutivo se emplea para explicar sistemas de resolución de problemas de optimización o búsqueda apoyados con un ordenador y utilizando modelos de computación aunado a una estrategia de evolución.

Por lo tanto, los algoritmos evolutivos actúan con una población de individuos o soluciones, que representan posibles soluciones a un problema. Dicha población se sujeta a un conjunto de modificaciones y posteriormente a un proceso de selección y cruce, que beneficia a los más aptos o mejores. Cada paso de modificación y selección constituye a una generación, de tal manera que después de un determinado número de generaciones se espera que el mejor individuo de la población se encuentre cerca de la solución deseada.

En optimización existen una cantidad considerable de metaheurísticas evolutivas o algoritmos basados en poblaciones, cuyo proceso para encontrar soluciones inicia desde múltiples puntos que evolucionan en paralelo dentro del espacio de búsqueda. Las metaheurísticas evolutivas que pueden encontrarse en la literatura son: algoritmos genéticos, algoritmos meméticos, algoritmos basados en nubes de partículas, búsqueda dispersa, entre otros. Los algoritmos evolutivos más populares y eficientes son los algoritmos genéticos. Los

algoritmos genéticos al igual que otras metaheurísticas difieren principalmente en la forma en que la búsqueda escapa de un óptimo local (Taha, 2012).

Según Andaluz (2018) los algoritmos genéticos constituyen una técnica poderosa de búsqueda y optimización con un comportamiento altamente paralelo, inspirado en el principio darwiniano de la selección natural y reproducción genética. En este principio de selección de los individuos más aptos, tienen mayor longevidad y por tanto mayor probabilidad de reproducción. Los individuos descendientes de estos individuos tienen una mayor posibilidad de transmitir sus códigos genéticos a las próximas generaciones.

De acuerdo a Taha (2012) el algoritmo genético (AG) imita el proceso de evolución biológica de “sobrevivencia del más apto”. Cada solución factible de un problema se considera como un *cromosoma* codificado por un conjunto de *genes*. Los *códigos genéticos* más comunes son el binario (0,1) y el numérico (0,1,2,..n). Asimismo, existen otros esquemas de codificación, incluido el código de nodo para modelos de red.

Un conjunto de N soluciones factibles se conoce como *población* con N cromosomas. La *aptitud* de un cromosoma se mide en términos de una función objetivo apropiada. Un cromosoma más apto da un mejor valor a la función objetivo. La idea general del AG es seleccionar dos *padres* a partir de una población. Los genes de los dos padres se *cruzan* entonces y (posiblemente) *mutan* para producir *hijos*. La descendencia reemplaza a los dos cromosomas más débiles (menos aptos) en la población, y el proceso de seleccionar nuevos padres se repite hasta obtener el *fenotipo* (solución óptima global o subóptimo del problema), el cual se considera como el individuo mejor evaluado en la función objetivo. Asimismo, Taha (2012) explica que la implementación real del AG requiere detalles adicionales del problema específico, además de que las reglas para seleccionar padres y crear hijos pueden variar, por ejemplo, los padres pueden ser seleccionados totalmente al azar de una población, o se pueden componer de los dos cromosomas más aptos.

3.8 Diagrama de funcionamiento de los Algoritmos Genéticos

La Figura 3.6 muestra el diagrama de funcionamiento esquemático de los Algoritmos Genéticos.

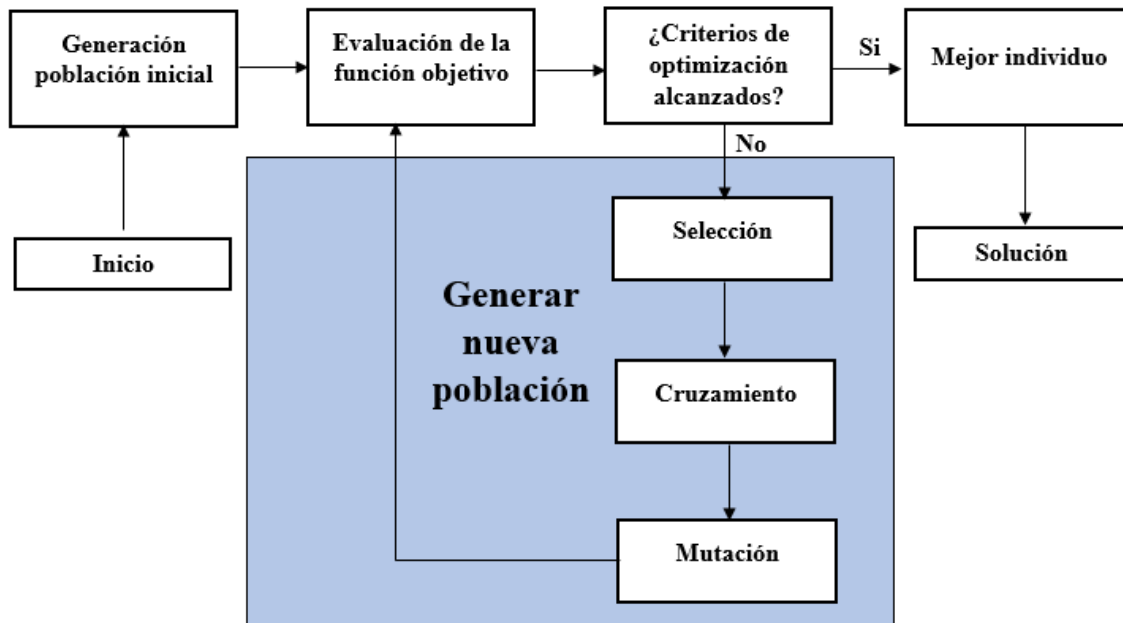


Figura 3. 6 Diagrama de funcionamiento esquemático de los algoritmos genéticos. Fuente: (Andaluz, 2018).

3.9 Diseño de Experimentos

Investigadores de prácticamente todos los campos de estudio llevan a cabo experimentos, por lo general para descubrir algo acerca de un proceso o sistema particular. Un experimento es una prueba. En una perspectiva más formal, un experimento puede definirse como una prueba o serie de pruebas en las que se hacen cambios deliberados en las variables de entrada de un proceso o sistema para observar e identificar las razones de los cambios que pudieran observarse en la respuesta de salida. En ingeniería, la experimentación desempeña un papel importante en el diseño de productos nuevos, el desarrollo de procesos de manufactura y el mejoramiento de procesos. El objetivo en muchos casos sería desarrollar un proceso robusto, es decir, un proceso que se afectado en forma mínima por fuentes de variabilidad externas (Montgomery, 2011).

De acuerdo a Gutiérrez Pulido & De la Vara Salazar (2008) en el campo de la industria es frecuente hacer experimentos o pruebas con la intención de resolver un problema o comprobar una idea (conjetura, hipótesis); por ejemplo, hacer algunos cambios en los materiales, métodos o condiciones de operación de un proceso, probar varias temperaturas en una máquina hasta encontrar la que brinda el mejor resultado o crear un nuevo material con la intención de lograr mejoras o eliminar algún problema.

Asimismo, Montgomery (2011) comenta que los experimentos se usan para estudiar el desempeño de procesos y sistemas. El proceso o sistema puede representarse con el modelo ilustrado en la Figura 3.7. En dicha figura, el proceso puede visualizarse como una combinación de máquinas, métodos, personas u otros recursos que transforman cierta entrada en una salida que tiene una o más respuestas observables. Algunas variables del proceso x_1, x_2, \dots, x_p son controlables, mientras que otras z_1, z_2, \dots, z_q son no controlables.

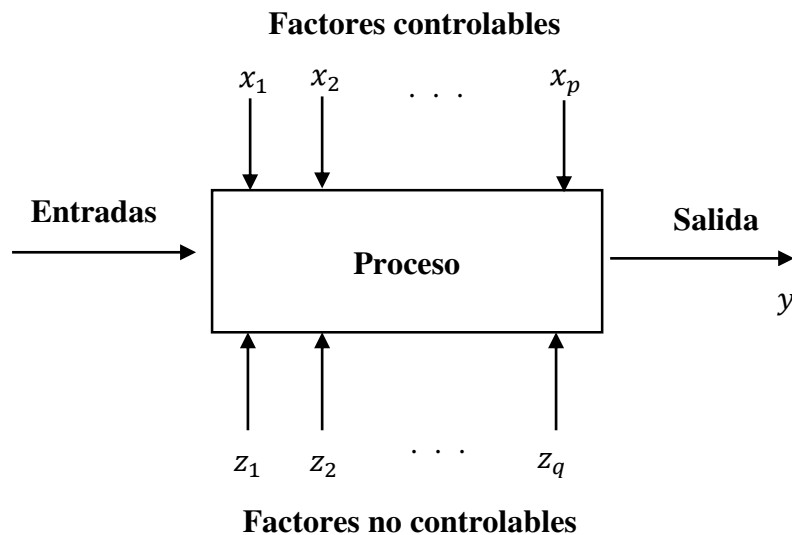


Figura 3.7 Modelo general de un proceso o sistema. Fuente: (Montgomery, 2011)

De acuerdo a Montgomery (2011) los objetivos del experimento podrían comprender los siguientes:

1. Determinar cuáles son las variables que tienen mayor influencia sobre la respuesta y .
2. Determinar cuál es el ajuste de las x que tiene mayor influencia para que y esté casi siempre cerca del valor nominal deseado.
3. Determinar cuál es el ajuste de las x que tiene mayor influencia para que la variabilidad de y sea reducida.
4. Determinar cuál es el ajuste de las x que tiene mayor influencia para que los efectos de las variables no controlables z_1, z_2, \dots, z_q sean mínimos.

Gutiérrez Pulido & De la Vara Salazar (2008) comentan que es común que los experimentos se hagan sobre la marcha, con base en el ensayo y error, apelando a la experiencia y a la intuición, en lugar de seguir un plan experimental adecuado que garantice una buena respuesta a las interrogantes planteadas. Es tal el poder de la experimentación que, en ocasiones, se logran mejoras a pesar de que el experimento se hizo con base en el ensayo y error. Sin embargo, en situaciones de cierta complejidad no es suficiente aplicar este tipo de experimentación por lo que es mejor proceder siempre en una forma eficaz que garantice la obtención de las respuestas a las interrogantes planteadas en un lapso corto de tiempo y utilizando pocos recursos.

El diseño estadístico de experimentos es precisamente la forma más eficaz de hacer pruebas o experimentación. El diseño de experimentos consiste en determinar cuáles pruebas se deben realizar y de qué manera, para obtener datos que, al ser analizados estadísticamente, proporcionen evidencias objetivas que permitan responder las interrogantes planteadas, y de esa manera clarificar los aspectos inciertos de un proceso, resolver un problema o lograr mejoras. De acuerdo a Gutiérrez Pulido & De la Vara Salazar (2008) algunos problemas típicos que pueden resolverse con el diseño y el análisis de experimentos son los siguientes:

1. Comparar a dos o más materiales con el fin de elegir al que mejor cumple los requerimientos.
2. Comparar varios instrumentos de medición para verificar si trabajan con la misma precisión y exactitud.
3. Determinar los factores (las x vitales) de un proceso que tienen impacto sobre una o más características del producto final.
4. Encontrar las condiciones de operación (temperatura, velocidad, humedad, por ejemplo) donde se reduzcan los defectos o se logre un mejor desempeño del proceso.
5. Reducir el tiempo de ciclo del proceso.
6. Hacer el proceso insensible o robusto a oscilaciones de variables ambientales.
7. Apoyar el diseño o rediseño de nuevos productos o procesos.
8. Ayudar a conocer y caracterizar nuevos materiales.

Asimismo, Gutiérrez Pulido & De la Vara Salazar (2008) indican que el Diseño de Experimentos (DDE) es un conjunto de técnicas activas, en el sentido de que no se espera

que el proceso mande las señales útiles, sino que éste se “manipula” para que proporcione la información que se requiere para su mejoría.

Por lo tanto, el Diseño de Experimentos es la aplicación del método científico para generar conocimiento acerca de un sistema o proceso, por medio de pruebas planeadas adecuadamente. Esta metodología se ha ido consolidando como un conjunto de técnicas estadísticas y de ingeniería, que permiten entender mejor situaciones complejas de relación causa-efecto (Gutiérrez Pulido & De la Vara Salazar, 2008).

De acuerdo a Montgomery (2011) al enfoque general para planear y llevar a cabo el experimento se le llama estrategia de experimentación. Algunas de las estrategias de experimentación existentes y las cuales podría usar un experimentador son:

1. Enfoque de la mejor conjetura. Éste enfoque consiste en seleccionar una combinación arbitraria de los factores, probarlos y ver qué ocurre. Después de correr dicha combinación arbitraria, el experimentador puede notar oscilación en los resultados y en consecuencia decidir cambiar el nivel de un factor en particular, manteniendo los demás factores en los mismos niveles usados anteriormente. Este enfoque podría continuar de manera casi indefinida, cambiando los niveles de uno (o quizá dos) de los factores para la prueba siguiente, con base en el resultado de la prueba en curso. Esta estrategia de experimentación, es común entre ingenieros y científicos. Funciona de manera adecuada si los experimentadores cuentan con una gran cantidad de conocimientos técnicos o teóricos del sistema que están estudiando, así como amplia experiencia práctica. Sin embargo, este enfoque presenta al menos dos desventajas. Primera, supóngase que la mejor conjetura inicial no produce los resultados deseados. Entonces el experimentador tiene que hacer otra conjetura acerca de la combinación correcta de los niveles de los factores. Esto podría continuar por mucho tiempo, sin garantía alguna de éxito. Segunda, supóngase que la mejor conjetura inicial produce un resultado satisfactorio. Entonces, el experimentador se ve tentado a suspender las pruebas, aun cuando no hay ninguna garantía de que se ha encontrado la mejor solución.
2. Enfoque de un factor a la vez. Éste método consiste en seleccionar un punto de partida, o línea base de los niveles, para cada factor, para después variar sucesivamente cada factor en su rango, manteniendo constantes los factores restantes

en el nivel base. Después de haber realizado todas las pruebas, se construye por lo general una serie de gráficas en las que se muestra la forma en que la variable de respuesta es afectada al variar cada factor manteniendo los demás factores constantes. La desventaja principal de la estrategia de un factor a la vez es que no puede tomar en consideración cualquier posible interacción entre los factores. Hay una interacción cuando uno de los factores no produce el mismo efecto en la respuesta con niveles diferentes de otro factor. Las interacciones entre factores son muy comunes y, en caso de existir, la estrategia de un factor a la vez casi siempre producirá resultados deficientes. Los experimentos de un factor a la vez siempre son menos eficientes que otros métodos basados en un enfoque estadístico del diseño experimental.

3. Enfoque factorial. Éste enfoque es el correcto para trabajar con varios factores. Un experimento factorial es una estrategia experimental en la que los factores se hacen variar en conjunto, en lugar de uno a la vez.

De acuerdo con Montgomery (2011) el diseño de un experimento consta de 7 pasos o pautas generales. La Figura 3.8 muestra los siete pasos para diseñar un experimento.

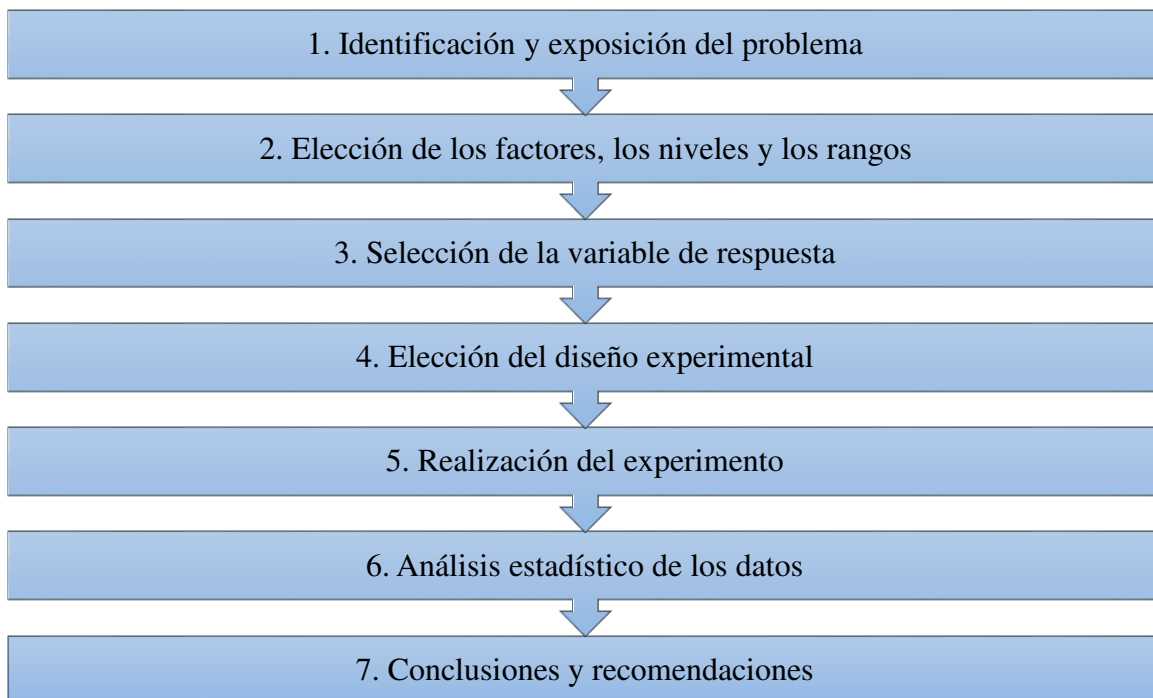


Figura 3. 8 Pautas generales para diseñar un experimento. Fuente: (Montgomery, 2011)

Los métodos del diseño experimental desempeñan también un papel importante en las actividades del diseño de ingeniería, donde se desarrollan productos nuevos y se hacen mejoramientos en los productos existentes. Entre las aplicaciones del diseño experimental en el diseño de ingeniería se encuentran (Montgomery, 2011):

1. La evaluación y comparación de configuraciones de diseños básicos.
2. La evaluación de materiales alternativos.
3. La selección de los parámetros del diseño para que el producto tenga un buen funcionamiento en una amplia variedad de condiciones de campo, es decir, para que el producto sea robusto.
4. La determinación de los parámetros clave del diseño del producto que afectan el desempeño del mismo.

De igual forma Montgomery (2011) señala que si un experimento quiere llevarse a cabo con la mayor eficiencia posible, es necesario utilizar un enfoque científico para planearlo. El diseño estadístico de experimentos se refiere al proceso para planear el experimento de tal forma que se recaben datos adecuados que puedan analizarse con métodos estadísticos que llevarán a conclusiones válidas y objetivas. El enfoque estadístico del diseño experimental es necesario si se quieren sacar conclusiones significativas de los datos. Cuando el problema incluye datos que están sujetos a errores experimentales, la metodología estadística es el único enfoque objetivo de análisis. Por lo tanto, cualquier problema experimental incluye dos aspectos: el diseño del experimento y el análisis estadístico de los datos. Estos dos aspectos se encuentran íntimamente relacionados porque el método de análisis depende directamente del diseño empleado.

Asimismo, Montgomery (2011) comenta que los tres principios básicos del diseño experimental son la realización de réplicas, la aleatorización y la formación de bloques. Por realización de réplicas se entiende la repetición del experimento básico. La realización de réplicas posee dos propiedades importantes. Primera, permite al experimentador obtener una estimación del error experimental. Segunda, si se usa la media muestral para estimar el efecto de un factor en el experimento, la realización de réplicas permite al experimentador obtener una estimación más precisa de este efecto.

Montgomery (2011) indica que la aleatorización es la piedra angular en la que se fundamenta el uso de los métodos estadísticos en el diseño experimental. Por aleatorización se entiende

que tanto la asignación del material experimental como el orden en que se realizarán las corridas o ensayos individuales del experimento se determinan al azar. Uno de los requisitos de los métodos estadísticos es que las observaciones (o los errores) sean variables aleatorias con distribuciones independientes. La aleatorización hace por lo general que este supuesto sea válido. La aleatorización correcta del experimento ayuda también a “sacar del promedio” los efectos de factores extraños que pudieran estar presentes.

La formación de bloques es una técnica de diseño que se utiliza para mejorar la precisión de las comparaciones que se hacen entre los factores de interés. Muchas veces la formación de bloques se emplea para reducir o eliminar la variabilidad transmitida por factores perturbadores; es decir, aquellos factores que pueden influir en la respuesta experimental pero en los que no hay un interés específico (Montgomery, 2011).

3.9.1 Diseño factorial 2^k

De acuerdo a Montgomery (2011) en muchos experimentos interviene el estudio de los efectos de dos o más factores. En general, los diseños factoriales son los más eficientes para este tipo de experimentos. Por diseño factorial se entiende que en cada ensayo o réplica completa del experimento se investigan todas las combinaciones posibles de los niveles de los factores. Por ejemplo, si el factor A tiene a niveles y el factor B tiene b niveles, cada réplica contiene todas las ab combinaciones de los tratamientos. Cuando los factores están incluidos en un diseño factorial, es común decir que están cruzados.

El efecto de un factor se define como el cambio observado en la variable de respuesta debido a un cambio de nivel de tal factor. En particular, los efectos principales son los cambios en la media de la variable de respuesta que se deben a la acción individual de cada factor. En términos matemáticos, el efecto principal de un factor con dos niveles es la diferencia entre la respuesta media observada cuando tal factor estuvo en su primer nivel, y la respuesta media observada cuando el factor estuvo en su segundo nivel (Gutiérrez Pulido & De la Vara Salazar, 2008).

Asimismo, Montgomery (2011) comenta que en algunos experimentos puede encontrarse que la diferencia en la respuesta entre los niveles de un factor no es la misma para todos los niveles de los otros factores. Cuando esto ocurre, existe una interacción entre los factores.

Los diseños factoriales se usan ampliamente en experimentos que incluyen varios factores cuando es necesario estudiar el efecto conjunto de los factores sobre una respuesta. Existen varios casos especiales del diseño factorial general que son importantes debido a su uso generalizado en el trabajo de investigación y porque constituyen las bases de otros diseños de gran valor práctico. El diseño factorial más importante de estos casos especiales es el de k factores, cada uno con sólo dos niveles. Estos niveles pueden ser cuantitativos, como dos valores de temperatura, presión o tiempo, o bien cualitativos, como dos máquinas, dos operadores, los niveles “alto” y “bajo” de un factor, o quizá la presencia o ausencia de un factor. Una réplica completa de este diseño requiere $2 \times 2 \times \dots \times 2 = 2^k$ observaciones y se le llama diseño factorial 2^k (Montgomery, 2011).

El diseño 2^k es de particular utilidad en las etapas iniciales del trabajo experimental, cuando probablemente se estén investigando muchos factores. Este diseño proporciona el menor número de corridas con las que pueden estudiarse k factores en un diseño factorial completo. Por consiguiente, estos diseños se usan ampliamente en los experimentos de tamizado o selección de factores. El primer diseño de la serie 2^k es el que sólo tiene dos factores, por ejemplo, A y B ; cada uno se corre a dos niveles. A este diseño se le llama diseño factorial 2^2 . Los niveles de los factores pueden denominarse arbitrariamente “bajo” y “alto”. En un diseño factorial 2^k es sencillo expresar los resultados del experimento en términos de un modelo de regresión. Puesto que 2^k es tan sólo un diseño factorial, podría usarse un modelo de los efectos o de las medias, pero el enfoque del modelo de regresión es mucho más natural e intuitivo (Montgomery, 2011).

El objetivo de un diseño factorial es estudiar el efecto de varios factores sobre una o varias respuestas, cuando se tiene el mismo interés sobre todos los factores. Por ejemplo, uno de los objetivos particulares más importantes que en ocasiones tiene un diseño factorial es determinar una combinación de niveles de los factores en la que el desempeño del proceso sea mejor. Con el diseño factorial completo se corren aleatoriamente todas las posibles combinaciones que pueden formarse con los niveles de los factores a investigar. Así, la matriz de diseño o arreglo factorial es el conjunto de puntos experimentales o tratamientos que pueden formarse considerando todas las posibles combinaciones de los niveles de los

factores. Para obtener el número de corridas experimentales se multiplica el número de tratamientos por el número de réplicas, donde una de éstas se lleva a cabo cada vez que se corre el arreglo completo. En general, la familia de diseños factoriales 2^k consiste en k factores, todos con dos niveles de prueba (Gutiérrez Pulido & De la Vara Salazar, 2008).

De acuerdo a Gutiérrez Pulido & De la Vara Salazar (2008), las ventajas de los diseños factoriales son:

1. Permiten estudiar el efecto individual y de interacción de los distintos factores.
2. Son diseños que se pueden aumentar para formar diseños compuestos en caso de que se requiera una exploración más completa. Por ejemplo, es útil aumentar el diseño si el comportamiento de la respuesta no es lineal en los factores controlados.
3. Se pueden correr fracciones de diseños factoriales, las cuales son de gran utilidad en las primeras etapas de una investigación que involucra a muchos factores, cuando interesa descartar de manera económica los que no son importantes, antes de hacer un estudio más detallado con los factores que sí son importantes.
4. Pueden utilizarse en combinación con diseños de bloques en situaciones en las que no puede correrse todo el diseño factorial bajo las mismas condiciones. Por ejemplo, cuando cada lote de material sólo alcanza para correr la mitad del experimento, éste se puede correr en dos bloques (dos lotes), lo cual implica repartir las pruebas en los dos lotes de la manera más conveniente posible.
5. La interpretación y el cálculo de los efectos en los experimentos factoriales se puede hacer con aritmética elemental, en particular cuando cada factor se prueba en dos niveles.

De acuerdo a Montgomery (2011) existen muchos paquetes de software de estadística que establecen y analizan diseños factoriales con dos niveles, como lo es Design-Expert. Una de las salidas de este programa de computadora es el Análisis de Varianza (ANOVA, por sus siglas en inglés). El análisis de varianza es una manera formal de determinar cuáles son los efectos de los factores que son diferentes de cero. El enfoque general para el análisis estadístico del diseño 2^k se presenta en la Figura 3.9. Como bien se señaló anteriormente, en este proceso de análisis suele emplearse un paquete de software de computadora.

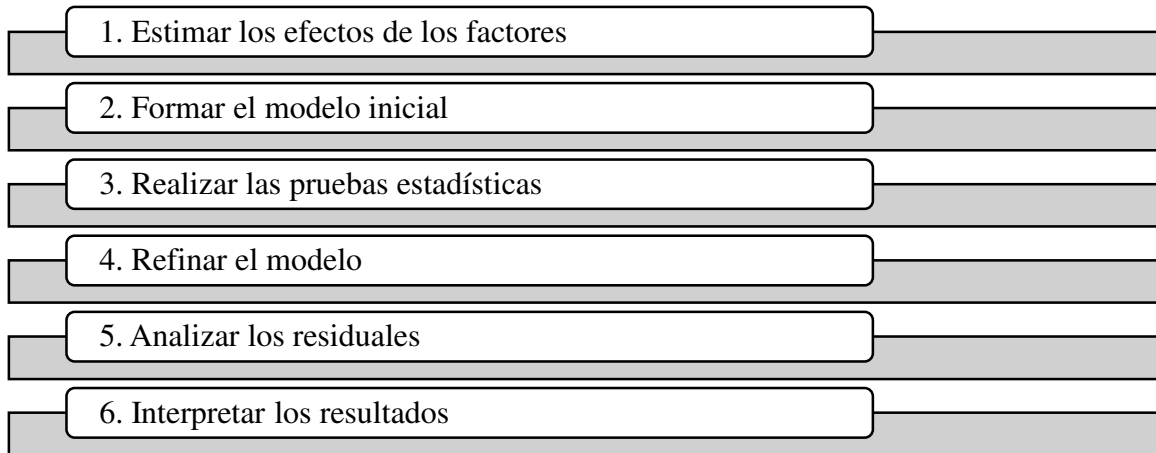


Figura 3. 9 Procedimiento de análisis para un diseño 2^k . Fuente: (Montgomery, 2011)

El primer paso de la Figura 3.9 consiste en estimar los efectos de los factores y examinar sus signos y magnitudes. De este modo el experimentador obtiene información preliminar respecto de los factores y las interacciones que pueden ser importantes, y en qué direcciones deberán ajustarse estos factores para mejorar la respuesta. El segundo paso consiste en formar el modelo inicial del experimento, por lo general se elige el modelo completo, es decir, todos los efectos principales y las interacciones, siempre que se haya hecho una réplica de al menos uno de los puntos del diseño. Después, en el paso 3 se usa el análisis de varianza para probar formalmente la significación de los efectos principales y las interacciones. El paso 4 consiste en la eliminación de las variables no significativas del modelo completo. El paso 5 es el análisis residual usual para verificar la adecuación del modelo y los supuestos (Error aleatorio: a) siga una distribución normal con media de cero y varianza, b) tenga varianza constante y c) independencia). El último paso consiste generalmente en el análisis gráfico: gráficas de los efectos principales o las interacciones, o superficies de respuesta y gráficas de contorno.

Además del ANOVA, un programa de computadora para el análisis estadístico del diseño 2^k , como Design-Expert, presenta varios estadísticos (Montgomery, 2011). La Tabla 3.1 describe los principales estadísticos.

Tabla 3. 1 Principales estadísticos. Fuente: Elaboración propia.

Nomenclatura	Nombre	Descripción
R^2	R^2 ordinaria o coeficiente de determinación	Mide la proporción de la variabilidad total explicada por el modelo. Este estadístico siempre se incrementa cuando se agregan factores al modelo, incluso cuando estos factores no son significativos.
$R^2\text{-adj}$	R^2 ajustada	Es un estadístico que está ajustado para el “tamaño” del modelo; es decir, para el número de factores. Este estadístico puede decrecer en realidad si se agregan términos no significativos al modelo.
PRESS	Suma de cuadrados del error de predicción (Prediction Error Sum of Squares en inglés)	El estadístico PRESS es una medida de qué tan bien predecirá datos nuevos el modelo. Un modelo con valor pequeño de PRESS indica que es posible que el modelo sea un buen predictor.
$R^2\text{-pred}$	R^2 de predicción	Este estadístico ofrece cierto indicio de la capacidad predictiva del modelo. El porcentaje que brinda expresa que el modelo “explica” la variabilidad al predecir nuevas observaciones. Por lo tanto, este estadístico es un criterio frecuentemente utilizado para evaluar la capacidad predictiva global de un modelo.

3.10 Estado del arte

Tabla 3. 2 Estado del arte. Fuente: Elaboración propia.

Año	Revista	Título	Autores	Resumen
2016	Optimization and Engineering	A hybrid extended pattern search/genetic algorithm for multi-stage wind farm optimization	(DuPont & Cagan, 2016)	<p>Se describe la fuerza impulsora que influye en la optimización del diseño de campos eólicos, cuya fuerza es el problema de colocar aerogeneradores a una distancia cercana, pudiendo estos experimentar déficits de desarrollo de energía debido a la disminución en la velocidad del viento inicial causada por las aspas giratorias de los aerogeneradores vecinos (aguas arriba). Asimismo, se menciona que la adición de más aerogeneradores a un sitio no necesariamente permitirá la generación de más potencia sino es preferible considerar posibles pérdidas o reducciones de energía entre los aerogeneradores para determinar el posicionamiento local de cada turbina. De igual forma, el artículo muestra que los grandes parques eólicos en tierra a menudo se instalan en fases discretas (es decir por etapas), con sub-campos más pequeños que se instalan y empiezan su operación, construyendo el parque eólico completo de manera fragmentada durante varios años. Para los autores de este artículo los parques eólicos que se construyen por etapas presentan un desafío de optimización complejo y relevante, ya que no solo el objetivo de construir un parque eólico es el desarrollo de energía y rendimiento, sino de igual modo se debe considerar conjuntamente la optimización de los sub-campos discretos como del parque completo.</p> <p>Para lo anterior, en el artículo se propone utilizar dos métodos de optimización: un algoritmo híbrido de Búsqueda de Patrones Ampliada/ Algoritmo Genético</p>

			<p>(aprovechando los beneficios de cada uno) y una Búsqueda de Patrones Ampliados multiobjetivos (es decir que no sólo se optimice cada uno de los subcampos adyacentes instalados sino de igual manera el campo eólico completo). También cabe destacar que este artículo comenta que el esfuerzo que ha realizado la computación para la optimización de los diseños de campos eólicos ha permanecido durante muchos años, sin embargo, debido a los recientes avances computacionales se han logrado resultados significativos para reducir el problema de optimización de campos eólicos.</p> <p>Como conclusión, el artículo expresa que mientras un Buscador de Patrones Ampliado tradicional (EPS por sus siglas en inglés) se ha aplicado previamente a la optimización de parques eólicos, estos nuevos algoritmos han permitido abordar un desafío significativo en esta área, en el sentido de que los grandes parques eólicos en tierra se instalan por etapas, lo que requiere métodos avanzados de optimización.</p>
2016	Journal of Heuristics	Proximity search heuristics for wind farm optimal layout	<p>(Fischetti & Monaci, 2016)</p> <p>Este artículo en primera instancia, describe como la energía verde se ha convertido en un tema de gran interés en los últimos años. Así mismo menciona como es que la sustentabilidad ambiental exige la considerable reducción en el uso de combustibles fósiles, los cuales son contaminantes e insostenibles. A consecuencia de lo anterior, los autores del artículo comentan que se han propuesto planes para la producción masiva de energía verde, incluida la energía eólica. Sin embargo, el artículo indica que existe un problema a atacar para desarrollar esta energía renovable, el cual se refiere al problema de optimización del diseño de campos eólicos. Dicho problema consiste en encontrar una asignación</p>

				<p>óptima de aerogeneradores en un sitio determinado, con el objetivo de maximizar la producción de energía. De igual manera, este artículo expresa que este problema estratégico resulta extremadamente difícil atacar en la práctica, debido a distintas consideraciones como: el tamaño de las instancias en aplicaciones reales y la presencia de factores no lineales. Este artículo expone un factor típico no lineal que se manifiesta en este problema, el cual es la interacción entre aerogeneradores, conocido como efecto de estela. Los autores describen este efecto como un fenómeno de interferencia para el cual, si dos aerogeneradores se ubican uno cerca del otro, el que interactúa en primera instancia con el viento crea una sombra para el que se encuentra instalado detrás (aguas abajo). Por lo que de acuerdo a los autores esto es de gran importancia en el diseño de distribución de aerogeneradores ya que este fenómeno da como resultado una pérdida de producción de energía para el aerogenerador aguas abajo, debido a que está posiblemente sujeto a una turbulencia intensa. Para este artículo, los autores consideran solo el modelo propuesto por Jensen para computar la interferencia entre un par de turbinas, por lo que asumen que la interferencia total es la suma de las interferencias pares. Sin embargo, comentan que aunque este modelo es una aproximación del contexto real, resulta ser lo suficientemente preciso para los propósitos de la implementación combinada de una heurística ad-hoc y programación lineal entera mixta para la optimización del diseño de aerogeneradores en un campo eólico.</p>
2015	Renewable Energy	Solving the wind farm layout optimization	(Feng & Shen Zhong, 2015)	En primera instancia, este artículo presenta una definición de campo eólico, así como los antecedentes sobre

		<p>problem using random search algorithm</p>	<p>el primer campo eólico instalado en tierra y el primer campo eólico instalado en el mar. Dicho artículo define un campo eólico como un grupo de aerogeneradores localizados en un sitio determinado cuya función es generar electricidad.</p> <p>En este artículo también se comenta que el desarrollo de parques eólicos se está convirtiendo en un proceso en un proceso altamente complejo que persigue múltiples objetivos bajo diferentes restricciones y esto a su vez implica diferentes tareas de diseño e ingeniería, las cuales pueden provenir de consideraciones logísticas, técnicas e incluso sociales.</p> <p>De igual forma en dicho artículo se comenta que de entre todas esas tareas una de las más críticas es la optimización del diseño de campos eólicos. Tal diseño de campos eólicos se refiere a la localización de aerogeneradores dentro de cierta área. Por lo tanto, el artículo hace referencia que la optimización del diseño de campos eólicos es determinar la posición de los aerogeneradores dentro del campo eólico para maximizar o minimizar según sea el caso algunas funciones objetivo, tales que maximicen la producción de energía y minimicen el costo tomando en consideración distintas restricciones.</p> <p>De igual manera, los autores en este artículo comentan que el problema de optimización del diseño de campos eólicos es un problema de optimización limitada debido a su no linealidad y el cual puede tratarse como un problema multi-objetivo entero-discreto-continuo sin formulaciones analíticas. Por lo que hacen énfasis en que este problema es matemáticamente complejo, el cual no se puede resolver mediante el uso de técnicas analíticas clásicas de optimización. En este artículo los</p>
--	--	--	---

			<p>autores formulan el problema de optimización del diseño de campos eólicos, en dicha formulación incluyen el modelado del viento, modelado del efecto estela, producción de energía, restricciones a considerar y la función objetivo que minimice el costo de energía por unidad producida. En este artículo se propone un algoritmo de búsqueda aleatoria (RS) basado en una formulación continua, el cual parte de un diseño inicialmente factible y luego mejora el diseño iterativamente en el espacio de solución factible.</p>
<p>2013</p>	<p>Energy Conversion and Management</p>	<p>Wind farm layout optimization using genetic algorithm with different hub height wind turbines</p>	<p>(Chen, Li, Jin, & Song, 2013)</p> <p>Este artículo describe cómo es que la contaminación ambiental afecta a los humanos, debido a que los principales combustibles utilizados para la vida diaria son combustibles fósiles, los cuales son insostenibles y predeciblemente se agotarán en el futuro a causa de recursos limitados, consumo excesivo, cambios de clima, calentamiento global, etc. De acuerdo al artículo, muchos investigadores están analizando cómo usar energía renovable, entre las que se encuentran: la energía solar, biomasa y energía eólica, las cuales cumplan como sustitutos de los recursos tradiciones para producir energía y con ello ayudar simultáneamente al cuidado del medio ambiente.</p> <p>Los autores del artículo comentan que en lo que respecta a la energía eólica, esta proporciona una mayor conversión de energía, más limpia y segura, por lo que estas características son sus mejores ventajas comparada con otros tipos de energía renovable. Sin embargo, el artículo describe que la gran variación, la incertidumbre, factores no predecibles y otras cuestiones afectan significativamente la estimación de la potencia eólica y la eficiencia de la captura de energía.</p>

			<p>Para lo anterior, el artículo muestra que la optimización de distribución es uno de los métodos para incrementar la tasa de utilización y la producción de energía en campos eólicos. En el presente artículo, los autores primero investigan el efecto de utilizar aerogeneradores con astas de diferente altura en un pequeño parque eólico con cierta energía de salida. Posteriormente, en este artículo se analizan tres diferentes condiciones de viento utilizando un algoritmo genético. De acuerdo al artículo, los resultados muestran que la energía de salida del campo eólico se incrementará al utilizar aerogeneradores con astas de diferente altura, incluso cuando el número total de aerogeneradores es el mismo en comparación con otro campo eólico que contiene aerogeneradores con astas de la misma altura. De igual forma, en este artículo se toman en cuenta modelos de costo para análisis, y los resultados muestran que al utilizar aerogeneradores con astas de diferente altura se puede mejorar también el costo por unidad de energía de un parque eólico.</p> <p>Cabe destacar que en este artículo, los autores usan Algoritmos Genéticos (GA) en MATLAB para optimizar el diseño de un campo eólico determinado con aerogeneradores de diferente altura. Los autores realizan lo anterior con la finalidad de investigar los beneficios del empleo de aerogeneradores con astas de diferente altura (en este caso utilizaron aerogeneradores con altura de 78 m y 50 m).</p> <p>Por último, para efectos de estudio, en este artículo los autores sólo consideran los siguientes factores: número de turbinas instaladas en un campo eólico dado, la altura de los aerogeneradores, direcciones y velocidades de viento, producción de energía y costo por</p>
--	--	--	--

				<p>unidad de energía de un campo eólico determinado.</p>
<p>2013</p>	<p>Renewable Energy</p>	<p>Offshore wind farm layout optimization using mathematical programming techniques</p>	<p>(Pérez, Mínguez, & Guanche, 2013)</p>	<p>El presente artículo menciona que, la energía eólica que producen los campos eólicos instalados en el mar es una energía renovable considerada como una energía renovable de creciente relevancia para los sistemas que suministran energía eléctrica actualmente, tales campos eólicos en el mar presentan condiciones de viento favorables a comparación con los campos eólicos instalados en tierra. De igual forma los autores mencionan que es necesario la compensación de los incrementos en costos de instalación y mantenimiento con el mayor rendimiento energético posible, por lo que resulta importante la optimización de recursos. El aspecto relevante que se menciona en el artículo para aumentar la rentabilidad es el diseño del parque eólico. Asimismo en el artículo se menciona que se utiliza el modelo de Jensen para predecir la energía de acuerdo a los déficits de velocidad del viento generados por los efectos estela. Para obtener un diseño adecuado del parque eólico, los autores de este artículo proponen un nuevo método para minimizar los efectos estela y con ello maximizar la potencia esperada de parques eólicos instalados en el mar. El método que se propone en este artículo utiliza un procedimiento secuencial para la optimización global, la cual consta de dos pasos: (1) un método heurístico para establecer una configuración de diseño aleatorio inicial y (2) el uso de técnicas de programación matemática no lineal para la optimización lineal, el cual utiliza el diseño aleatorio como solución inicial. De acuerdo al artículo, el método aprovecha al máximo las técnicas de programación matemática mientras se considera un enfoque de optimización</p>

				<p>global, lo cual de acuerdo a los autores es fácilmente paralelizable. El método propuesto en este artículo se implementó en un campo eólico en Alemania, llamado Alpha Venus, por lo que se aprobó el rendimiento del procedimiento propuesto, obteniendo un incremento de la producción de energía anual esperada de 3.52% en comparación con la configuración real del campo eólico. Con el incremento en la producción, los autores mencionan que de acuerdo a los precios de la electricidad en Alemania, este incremento de igual forma constituye un incremento esperado en ganancias anuales.</p>
2013	Renewable Energy	Wind farm layout optimization using particle filtering approach	(Eroğlu & Seçkiner, 2013)	<p>En el presente artículo se expone un enfoque de filtrado de partículas para obtener un diseño de campo eólico optimizado, el cual se vea afectado de forma mínima por los efectos estela y a través de la reducción de este fenómeno genere la máxima energía. De acuerdo al artículo existen dos restricciones principales, la cuales se consideraran necesarias para obtener un diseño adecuado de campo eólico, las cuales son; el limite o dimensiones del parque eólico y la distancia entre dos turbinas entre sí. Los autores en el presente trabajo integran a la metodología de solución las restricciones y los efectos estela producidos por los aerogeneradores. De acuerdo al artículo el filtrado de partículas es un nuevo enfoque y se utiliza para optimizar el modelo de diseño del problema con tres casos diferentes de velocidad del viento, así como la distribución de dirección del sitio ventoso. En el presente artículo se expone que el modelo utilizado para modelar y calcular los déficits de velocidad derivados de los efectos estela es el modelo de Jensen. Los resultados del presente artículo muestran que el enfoque de filtrado de partículas puede</p>

				competir en cuanto a soluciones de calidad con otros métodos de optimización bioinspirados como el algoritmo de colonia de hormigas y los algoritmos de estrategia evolutiva.
2012	Renewable Energy	Design of wind farm layout using ant colony algorithm	(Eroğlu & Seçkiner, 2012)	En primera instancia, los autores del artículo comentan que el viento es una fuente de energía limpia, abundante y completamente renovable. Asimismo se expone que grandes campos eólicos están siendo construidos en todo el mundo como una manera de más limpia de generar de generar electricidad, sin embargo se expone que los diseñadores de campos eólicos aún están buscando diseños de campos eólicos más eficientes para maximizar la captura y producción de energía eólica. En el presente artículo se propone un algoritmo de colonia de hormigas para maximizar la producción de energía esperada. De esta manera, el algoritmo considera la pérdida de energía ocasionada por el efecto estela, la cual se calcula en función de la ubicación de los aerogeneradores y la dirección del viento. El modelo que se propone en el presente documento se presenta con tres diferentes escenarios de velocidad del viento y una distribución direccional del mismo viento en el sitio ventoso. De igual forma en el presente artículo que el modelo utilizado para calcular los déficits de velocidad generados por los aerogeneradores es el modelo desarrollado por Jensen. De acuerdo al artículo, los resultados muestran que el algoritmo de colonia de hormigas funciona de mejor manera, incluso por encima de estrategias presentes en la literatura, en términos de obtención de valores máximos de producción de energía esperada y pérdidas de energía provocadas por los efectos estela.
2012	Renewable Energy	Wind farm micro-siting by Gaussian	(Wan, Wang ,	El presente artículo expone que recientemente la micro-ubicación de

		<p>particle swarm optimization with local search strategy</p>	<p>Yang, Gu, & Zhang , 2012)</p>	<p>campos eólicos ha atraído mucha atención debido al floreciente desarrollo de la energía eólica. En el artículo de identifica el objetivo principal, el cual consiste en maximizar la potencia energética extraída de un campo eólico mientras se satisface la distancia requerida entre los aerogeneradores para garantizar la seguridad de operación de cada una de ellas. De acuerdo al artículo, el problema de micro-ubicación es por naturaleza un problema de optimización restringido, en el que el acoplamiento y acumulación de los efectos estela es fuerte y el número de restricciones de posición entre turbinas es grande. Por lo tanto, en el presente artículo se propone un algoritmo de optimización de enjambre de partículas Gaussiano mejorado para optimizar las posiciones de los aerogeneradores en el espacio continuo. De igual manera, los autores del artículo comentan que para prevenir que el algoritmo sea prematuro, se incorporó una estrategia de búsqueda local basada en la evolución diferencial para buscar en la región prometedora lograda por la optimización del enjambre de partículas. Asimismo, en el artículo se expone que se empleó un método simple basado en la viabilidad para comparar el rendimiento de diferentes configuraciones o diseños. De la misma manera, en el artículo se explica que en un campo eólico, los efectos entre turbinas podrían aproximarse a un modelo lineal, por lo que para calcular la velocidad de viento a una distancia corriente abajo consideran el Teorema del balance de momento y la teoría de Betz. De acuerdo al artículo, los resultados completos de la simulación demostraron que las configuraciones de micro-ubicación obtenidas por el algoritmo propuesto aumentan la generación de energía del parque eólico. En adición, el</p>
--	--	---	--------------------------------------	---

				<p>artículo expone que el tiempo de ejecución del algoritmo se reduce significativamente, lo cual es sumamente importante especialmente para los parques eólicos a gran escala.</p>
2010	Renewable Energy	New approach on optimization in placement of wind turbines within wind farm by genetic algorithms	(Emami & Noghreh, 2010)	<p>De acuerdo al presente artículo, la ubicación de los aerogeneradores en un campo eólico se ha resuelto con una nueva codificación y también una función objetivo novedosa en cuanto al enfoque de algoritmos genéticos. De acuerdo a los autores, en comparación con trabajos anteriores, los resultados se han mejorado notablemente. La función objetivo presentada en el presente artículo aunada a coeficientes ajustables, proporciona un mayor control sobre el costo, la potencia o energía y la eficiencia del parque eólico en comparación con funciones objetivos presentadas en trabajos previos. De igual forma, el artículo expone que anteriormente era necesario considerar algunas subpoblaciones al igual que individuos, sin embargo, los autores comentan que no es necesario utilizar las subpoblaciones, sino basta con aplicar un nuevo enfoque de codificación para resolver este problema. Por lo tanto, ejecutar el algoritmo genético solo una vez para cada caso es suficiente. De igual forma, en el presente trabajo y bajo este enfoque se consideran tres casos: (a) viento uniforme proveniente de una sola dirección, (b) viento uniforme con dirección variable y (c) viento no uniforme con dirección variable. Asimismo, el artículo expone que para el caso (a) 10 individuos evolucionan a lo largo de 150 generaciones. Para el caso (b) 20 individuos evolucionan durante 150 generaciones. Para el caso (c) el algoritmo inicia con 20 individuos que evolucionan durante 100 generaciones. El modelo usado en el presente artículo para modelar los efectos estela y calcular los déficits de los mismos es</p>

			<p>similar al modelo de efecto estela desarrollado por N.O Jensen. Los resultados arrojados en el presente documento muestran que se obtuvieron las configuraciones óptimas para cada caso. Además de las configuraciones óptimas, los resultados incluyen la aptitud de la función objetivo, la energía total producida, la eficiencia de la energía producida, el número de turbinas y los coeficientes de la función objetivo para cada configuración.</p>
--	--	--	---

Capítulo 4. Método

En la figura 4.1 se muestra el diagrama que contiene las etapas específicas del método de trabajo para este proyecto.

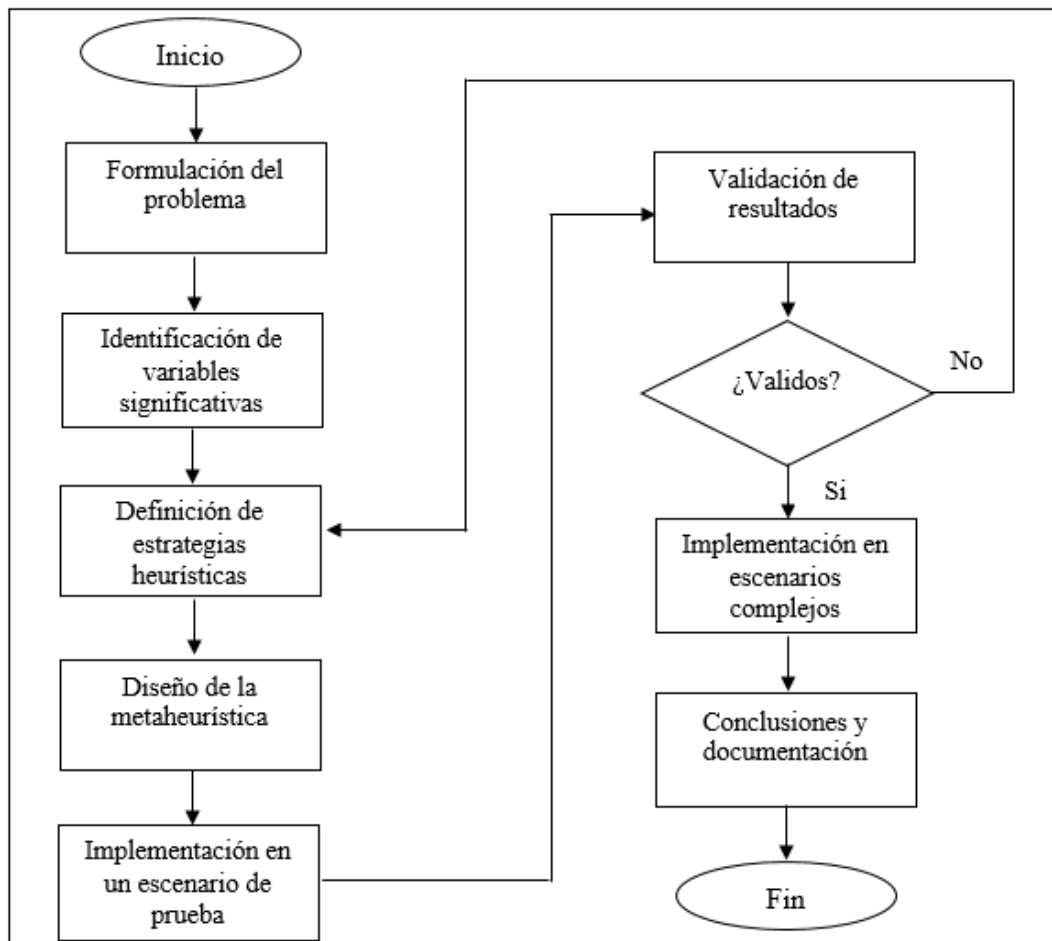


Figura 4. 1 Etapas del método de trabajo. Elaboración propia.

A continuación se describen cada una de las etapas del método de trabajo a implementar para un adecuado desarrollo del tema de investigación.

4.1 Formulación del problema de optimización en campos eólicos

En esta etapa en primera instancia se realizó una involucración pertinente en este tipo de temas relacionados con la producción de energía verde, la cual incluyó la revisión de conceptos, elementos y aspectos relevantes sobre este tema en específico.

Posteriormente en esta etapa se formuló de manera concisa y precisa el problema de optimización de campos eólicos a través de la revisión de la literatura científica, con la finalidad de comprender la relevancia y estado actual de este problema, así como identificar

las consideraciones necesarias para catalogar de manera correcta dicho problema de optimización. Una vez identificada la categorización de dicho problema, como culminación de esta etapa se procedió a generar una estrategia conceptualizada de cómo afrontar el problema de optimización.

4.2 Identificación de las variables significativas a abordar en el problema

En esta etapa se identificaron y analizaron las variables significativas asociadas a este problema de optimización, con la intención de exponer y representar los aspectos relevantes del sistema real (campos eólicos), así como se promovieron los conocimientos e ideas válidas necesarias para atacar las variables que intervienen en el problema de optimización de campos eólicos.

4.3 Definición de las estrategias y procedimientos heurísticos

Una vez identificadas y analizadas las variables significativas, en esta etapa se definieron las estrategias y los procedimientos heurísticos esenciales a utilizar para afrontar el problema de optimización de campos eólicos. Esta etapa resultó de suma importancia debido a que los procedimientos heurísticos fueron la base para modelar de manera conveniente el comportamiento de los factores significativos en el sistema.

De acuerdo a los análisis preliminares, uno de los procedimientos heurísticos que se consideraron en esta etapa fue la discretización del campo eólico en análisis, así como el modelado del efecto estela.

4.3.1 Discretización del campo eólico

Para reducir la complejidad del problema de optimización de diseño de campos eólicos y así obtener soluciones de buena calidad, se realizó la discretización del campo eólico a través de pequeñas cuadrículas. Esto es porque para efectos del presente trabajo solo se consideran campos eólicos totalmente planos y cuadrados, los cuales se dividen en pequeñas celdas cuadriculadas. Los centroides o puntos dentro de las cuadrículas representan las posibles localizaciones o ubicaciones donde podría ser instalada una turbina.

En la Figura 4.2 se presenta un diseño propuesto (escenario) para un campo eólico de 600 m x 600 m, en el cual se puede observar la discretización del mismo, con la finalidad de precisar en el centro de cada cuadrícula, la posible localización o ubicación central (anillo), donde

podría asignarse o instalarse un aerogenerador. Para este diseño específico de campo eólico, se un conjunto predefinido de 25 posibles localizaciones discretas con dimensiones de 120 m x 120 m, de las cuales en 11 de ellas se tiene asignado o instalado un aerogenerador (representados con anillos rellenos de color rojo). Asimismo, en el escenario del campo eólico propuesto se manifiesta cierto viento con velocidad inicial (U_0) con una dirección dominante de Norte a Sur. Esta estrategia de discretización es de gran ayuda debido a que, si el campo eólico no se discretizara, el algoritmo utilizado tardaría mucho tiempo en encontrar una solución dentro de un espacio de solución continuo.

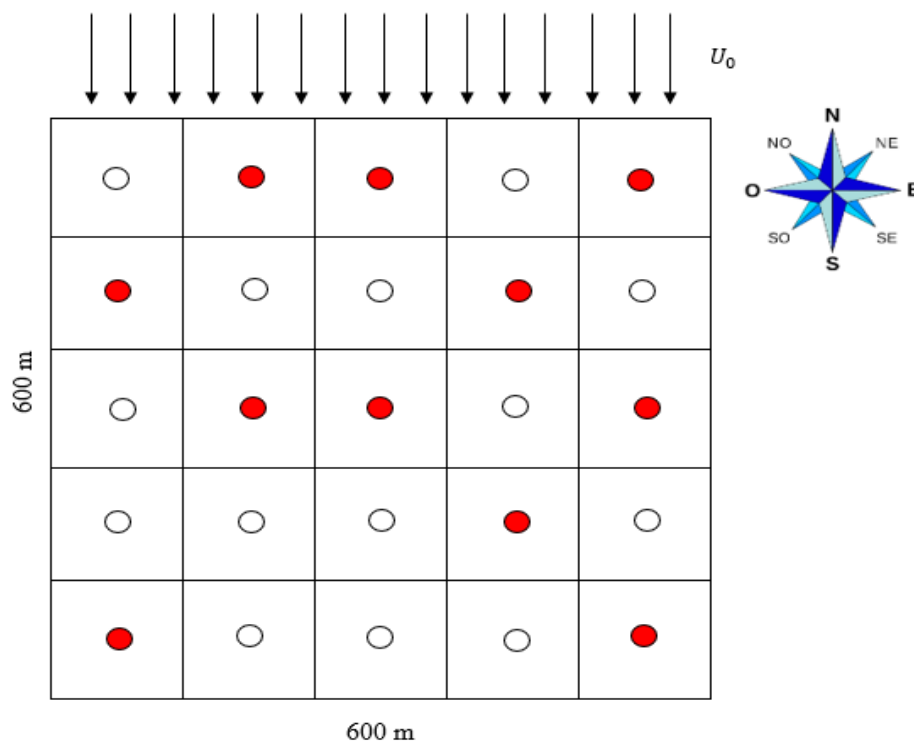


Figura 4.2 Campo eólico discreto. Fuente: Elaboración propia.

En adición, sin duda alguna la estrategia heurística que se consideró de mayor importancia y relevancia en el presente proyecto fue la modelación del efecto estela. Dicho propósito de modelación permitió calcular con precisión los déficits de velocidad del viento y por consecuencia la pérdida de energía en cada aerogenerador afectado por este fenómeno. En el paquete empleado para optimizar (el paquete se describe en la etapa 4.4) también se considera el modelo de Jensen para calcular los déficits de velocidad causados por los efectos estela

entre dos o más aerogeneradores. El modelo de Jensen considerado dentro del paquete resultó sumamente útil, debido a su simplicidad y relativamente alto grado de precisión.

4.4 Diseño de la metaheurística evolutiva (Algoritmo Genético)

En esta etapa, se utilizó el código libre del Algoritmo Genético (GA por sus siglas en inglés) desarrollado por Gatscha (2016) y el cual se encuentra disponible en el paquete ‘windfarmGA’ (Genetic Algorithm for Wind Farm Layout Optimization) (Versión 1.2.1) del software Rstudio (Versión 1.1.456). El paquete ‘windfarmGA’ fue descargado de CRAN (2018). El GA incluido en el paquete se utilizó con el objetivo de encontrar la mejor distribución de aerogeneradores en un campo eólico determinado considerando los efectos estela a través del modelo de Jensen. El paquete considera el modelo de Jensen para evaluar los déficits de velocidad del viento entre las turbinas afectadas. Asimismo, el paquete modela efectos estela completos y parciales (Gatscha, 2016). El propósito principal del GA como herramienta de búsqueda global es evitar las soluciones óptimas locales generando soluciones aleatoriamente. Como bien se explicó en el marco teórico, el algoritmo genético (GA) imita el proceso de evolución biológica de “sobrevivencia del más apto”. Cada solución factible de un problema se considera como un cromosoma codificado por un conjunto de genes. Los códigos genéticos más comunes son el binario (0,1). En esta investigación, el valor de 0 en un cromosoma representa que no existe un aerogenerador instalado en un centroide o posible localización, mientras que el valor de 1 en un cromosoma representa que existe un aerogenerador instalado en el centroide correspondiente. Por lo tanto, el algoritmo genético del paquete utilizado en esta investigación, primero genera de manera aleatoria un conjunto de cadenas o cromosomas binarios. Cada cromosoma es un individuo, el cual representa un diseño o configuración del campo eólico en estudio. Al conjunto de individuos se le llama población.

Como bien se comentó en el marco teórico, el algoritmo genético trabaja principalmente con tres operadores genéticos: selección, cruce y mutación. El operador de selección consiste en seleccionar y retener una cierta cantidad de individuos que pueden generar mejores valores de aptitud en cada iteración (generación) de acuerdo a la probabilidad de selección predefinida o al método de selección elegido. En el paquete de optimización utilizado en esta investigación es posible realizar diferentes ajustes en los parámetros o variables de entrada,

como por ejemplo en la variable de selección “selstate”, donde los posibles valores de entrada o métodos de selección son “FIX” y “VAR”. Cuando el algoritmo realiza el proceso de selección, elimina los peores cuatro individuos de la población según los valores de aptitud. Una vez seleccionados los individuos (padres), el algoritmo realiza el cruce en función de la probabilidad o al método de cruzamiento seleccionado. El operador de cruzamiento cumple la labor de combinar información genética de los individuos para poder procrear hijos a partir de los padres seleccionados y con ello encontrar individuos más aptos o mejor evaluados en la función de aptitud. De igual forma, la variable de entrada del método de cruzamiento “crossPart1” puede definirse como “EQU” o “RAN” según se desee. En la tabla 4.1 se describen los métodos de selección y cruzamiento utilizados en el algoritmo. Asimismo, el operador de mutación se realiza después del cruzamiento, cuya función es aumentar la diversidad de los individuos para evitar la convergencia prematura a óptimos locales. En el paquete de Rstudio, el parámetro de la tasa de mutación también puede ajustarse de acuerdo al porcentaje de individuos que se desea mutar en cada iteración. Después de la selección, el cruce y la mutación, los individuos más aptos o con mejores resultados se transfieren a la siguiente generación. Los individuos menos aptos se remueven simultáneamente. La selección elitista también puede considerarse en el algoritmo. Si el método de elitismo se activa, la variable de entrada “nelit” determina el número de individuos que deben salvarse para formar parte de la población de elite. Esta población de elite no se guarda por separado, sin embargo, sus valores de aptitud aumentan en un factor de 10, principalmente para simplificar la implementación. La probabilidad de que estos individuos sean seleccionados es, por lo tanto, mucho más alta que la de los individuos restantes, aunque el proceso de selección seguirá siendo aleatorio. En la tabla 4.1 se describe el método de elitismo.

Tabla 4. 1 Descripción de los métodos de cruce, elitismo y selección utilizados en el algoritmo.

Método de cruce	“EQU” Este método divide el código genético en intervalos o partes iguales.	“RAN” Este método de cruce divide el código genético en ubicaciones aleatorias.
Método de selección	“FIX”	“VAR”

	Este método de selección elige un valor constante del 50% del total de individuos de la población para procrear nuevas soluciones (individuos) en la próxima generación.	Este método selecciona un porcentaje variable dependiendo del desarrollo de los valores de aptitud de la población actual, en comparación con la población anterior.
Elitismo	<p>“TRUE”</p> <p>Este valor de la variable de elitismo activa la selección elitista, lo cual garantiza seleccionar los mejores individuos en cada iteración.</p>	<p>“FALSE”</p> <p>Si el método de elitismo se declara en “FALSE” la selección elitista no se activa.</p>

En Gatscha (2016) se explican a detalle las características y consideraciones de los métodos de selección, cruzamiento, mutación y elitismo considerados en el paquete del algoritmo. De igual forma, Gatscha (2016) describe detalladamente otros parámetros que pueden ajustarse en el paquete, los cuales son ajenos al algoritmo genético, pero que forman parte esencial en el diseño óptimo de campos eólicos, tal como: método de mallado (Grid Method) y rugosidad del terreno (Surface Roughness). Asimismo, en Gatscha (2016) se muestra y describe la fórmula con la que se calculan las cantidades de energía que producen tanto los aerogeneradores afectados por los efectos estela como aquellos que no son afectados por tal fenómeno.

Finalmente, el algoritmo cuenta con dos criterios de paro: el algoritmo se detiene cuando la cantidad de generaciones excede el número de iteraciones predefinido en la variable de entrada “iteration” o cuando se encuentra un diseño de campo eólico con una eficiencia del 100%.

La ecuación (4.1) representa la función objetivo a optimizar y en la cual se evalúan los valores de aptitud de cada una de las soluciones (individuos) generados por el algoritmo. Las ecuaciones (4.2) y (4.3) representan las restricciones a considerar.

$$\text{Max } Z = \sum_{j=1}^N P_{ij} X_{ij} \quad (4.1)$$

$$\text{s.a. } X_{ij} \leq 1 \quad (4.2)$$

$$X_{ij} \in \{0,1\} \quad (4.3)$$

Donde:

P_{ij} : Potencia instantánea generada por la turbina "j", debido a la interferencia de "i".
(continua en unidades de potencia).

Z = Potencia total producida (continua en unidades de potencia).

N= Número de turbinas a instalar.

$$X_{ij} = \begin{cases} 1 & \text{Si se encuentra una turbina instalada en la posición } j, \text{ la cual es afectada por } i \\ 0 & \text{Otro caso} \end{cases}$$

Estrategia de implementación del Algoritmo Genético para el escenario propuesto en la subsección 4.3.1 del presente capítulo:

1. Generar una población inicial de individuos al azar P a la que se les llamará padres. En el paquete utilizado, el algoritmo genera para la población inicial aleatoriamente 100 individuos o cromosomas. Para este escenario, cada individuo consta de una cadena binaria de 25 posiciones o genes. Considérese que un valor de 1 en una posición representa una turbina instalada en el centroide correspondiente y 0 otro caso. Para localizar una turbina en el campo eólico discreto, las posibles localizaciones o centroides se enumeran por renglones. En la Figura 4.3 se muestra un ejemplo de 5 individuos (a-d) generados aleatoriamente, en el que cada uno corresponde un diseño específico o configuración del campo eólico.




Figura 4. 3 Individuos generados aleatoriamente para la población inicial. Fuente: Elaboración propia.

2. Calcular la función de aptitud $F(x)$ de acuerdo a la ecuación (4.1) para cada uno de los padres de P .
3. Se ordenarán los valores proporcionales obtenidos de la evaluación de la función objetivo de los individuos (padres), del menor al mayor, mediante la división de:

$$\frac{F(x)}{\sum F(x)}$$
4. \longrightarrow *While* (De acuerdo a los criterios de parada).
5. Seleccionar una población para el operador de variación cruce: Método “FIX” o Método “VAR”. Por medio del Método de la Ruleta y de acuerdo al método de selección elegido se seleccionarán los individuos (padres) más aptos para crear parejas y procrear los hijos.
6. Cruzar a los individuos (padres): Método “EQU” o Método “RAN”. Por lo tanto de acuerdo al método seleccionado se eligen dos padres para compartir su información genética. Como ejemplo, en la Figura 4.4 se muestran dos individuos presentados en el paso 1.




Figura 4. 4 Padres seleccionados para compartir su información genética en la posición 10 del cromosoma. Fuente: Elaboración propia.

Los padres (a) y (b) procrearán dos nuevos hijos (A-D, C-B) con nueva información genética, es decir nuevos cromosomas con genes compartidos. La Figura 4.5 muestra los nuevos individuos (hijos) creados a partir de los padres.




Figura 4. 5 Nuevos individuos procreados. Fuente: Elaboración propia.

- Mutar a los hijos con cierta tasa de probabilidad. De acuerdo a Gatscha (2016) la tasa de mutación se debería considerar bastante pequeña, por lo que se recomienda en un rango de 0.01% a 0.10% e incluso también se recomienda complementar una tasa de mutación fija con una tasa de mutación variable. En el cromosoma o cadena binaria del hijo seleccionado para mutación se elegirá una posición por probabilidad aleatoria y en dicha posición se modificará el gen, si contenía un valor 0, este se cambiará por 1 y viceversa según sea el caso. En la Figura 4.6 se presenta un ejemplo de mutación en la posición 14 del hijo #1 procreado en el paso 6.




Figura 4. 6 Hijo #1 mutado en la posición 14. Fuente. Elaboración propia.

Nota: El cruzamiento y la función de mutación cambian el número de aerogeneradores en los campos eólicos. Sin embargo, el algoritmo está diseñado para funcionar con un número constante de turbinas. Esto sucede debido a que el valor de aptitud de un individuo es la producción de energía esperada.

8. Calcular la función de aptitud $F(x)$ de los hijos procreados. Se ordenarán los valores proporcionales obtenidos de la evaluación de la función objetivo de los nuevos individuos (hijos), del menor al mayor, mediante la división de: $\frac{F(x)}{\sum F(x)}$.
9. Insertar hijos en P . Se remplazarán los hijos más fuertes o aptos por los padres débiles, se irá actualizando P hasta que se procee el individuo con el mejor valor de aptitud evaluado en la función objetivo. A este individuo le llamaremos fenotipo de mejor solución. El algoritmo arroja el fenotipo encontrado de todas las iteraciones.

Como resumen de la presente etapa, se muestra la adaptación del pseudocódigo a implementar del Algoritmo Genético propuesto por Bilbao & Alba (2011).

Algoritmo Genético

```

1:  $t \leftarrow 0$ ; /* contador de iteraciones */
2: inicializar ( $Pa$ ) /*Inicializa la población */
3: mientras no hay criterio de parada ( $t, Pa$ ) hacer
4:    $Padres \leftarrow$  selección ( $Pa$ ); /* Seleccionar padres */
5:    $Hijos \leftarrow$  reproducción ( $Padres$ ) /* Cruce */
6:   mutación ( $Hijos$ ) /* mutar los hijos */
7:   evaluar ( $Hijos$ ) /* evaluar los hijos */
8:    $nuevaGeneración =$  reemplazo ( $Pa, Hijos$ ) /* reemplazo la población por la actual */
9:    $t \leftarrow t + 1$  /* Una iteración más */
10: fin mientras
11: Retornar: mejor solución encontrada.

```

Figura 4. 7 Pseudocódigo del algoritmo genético. Fuente: *Bilbao & Alba (2011)*

4.5 Implementación de la metaheurística evolutiva en un escenario de estudio

En esta etapa se implementó la metaheurística evolutiva incluida en el paquete “windfarmGA” en un escenario de estudio con 36 posibles localizaciones y 12 turbinas a instalar, el cual se tomó como base para aplicar el Diseño de Experimentos. Asimismo, en esta etapa se determinó que para efectos del presente proyecto, en cada instancia de campo eólico a optimizar sólo se considerarían aerogeneradores con rotor del mismo radio.

4.6 Validación de los resultados obtenidos en la implementación de la metaheurística evolutiva

En esta etapa se validaron los resultados obtenidos de la implementación del algoritmo en el escenario base para determinar si efectivamente nuestros parámetros propuestos brindaban soluciones de buena calidad (es decir aquella distribución de aerogeneradores que produjera la mayor cantidad de energía posible) en un tiempo de cómputo razonable. La validación se llevó a cabo con la técnica de Diseño de Experimentos, decidiendo utilizar un diseño factorial 2^k en un escenario de prueba (36 posibles localizaciones y 12 turbinas a instalar) con la finalidad de encontrar aquellos parámetros que brindaran la máxima cantidad de energía para utilizarlos en escenarios más complejos, como fueron las variantes del Caso 2.

4.7 Implementación de la metaheurística evolutiva en escenarios más complejos y validación de los resultados obtenidos de estas implementaciones.

Una vez validados los resultados obtenidos tras la implementación del algoritmo evolutivo en el escenario base, se implementó en escenarios más complejos, como fueron las variantes del Caso 2 (100 posibles localizaciones y 30 turbinas a instalar). Al implementar el algoritmo en estas variantes considerando los parámetros recomendados, efectivamente se determinó que el algoritmo convergía en soluciones de muy alta calidad en tiempos de cómputo razonables.

4.8 Conclusiones y documentación

En esta etapa se realizaron las conclusiones pertinentes para este proyecto. Una vez desarrolladas las etapas anteriormente descritas, se sintetizaron los resultados obtenidos de la implementación del algoritmo en el escenario de estudio base, posteriormente se sintetizaron los resultados obtenidos de las implementaciones en escenarios complejos, con la finalidad de brindar una interpretación general de los resultados obtenidos a través de las implementaciones del algoritmo para resolver los distintos escenarios. Los resultados y hallazgos se interpretaron debidamente. Asimismo, con las soluciones energéticas encontradas en cada una de las instancias resueltas en este trabajo, se realizó un análisis de abastecimiento de energía y un análisis monetario.

Capítulo 5. Resultados y conclusiones

5.1 Resultados

En la presente sección se resuelven dos instancias propuestas en Gatscha (2016). El Caso 1 corresponde a una instancia pequeña. El Caso 2 corresponde a una instancia de 100 posibles localizaciones y 30 turbinas a instalar. El Caso 2 se resuelve en tres variedades (Caso 2(a), Caso 2(b) y Caso 2(c)). Las características para cada variante del Caso 2 se explican al inicio de cada subsección.

Con la finalidad de encontrar los parámetros adecuados, es decir aquellos parámetros que brinden soluciones de alta calidad en tiempos de cómputo razonables a los casos que en esta investigación se resuelven, se desarrolla un diseño experimental 2^k en Design Expert, donde se consideran 5 factores de manipulación en el Algoritmo Genético y 2 niveles para cada uno de los factores. Las variables de respuesta que se consideran en el experimento son la Energía en kWh y el Tiempo de CPU en segundos. El experimento se replicó 3 veces. Asimismo, se consideran 8 puntos centrales para determinar si existe un efecto no lineal o curvatura entre las variables de respuesta y los factores incluidos en el experimento. Se decidió utilizar un diseño 2^k debido a que los factores que se consideran tienen dos niveles cada uno, asimismo porque un diseño factorial completo no correlaciona los factores principales ni las interacciones como es el caso de los factoriales fraccionados. Además, se decidió utilizar 3 réplicas con la finalidad de estimar la media y la desviación estándar de los datos obtenidos en las variables de respuesta al ejecutar los tratamientos. Adicionalmente, para justificar el uso de 3 réplicas y 8 puntos centrales en el experimento, se comprobó en Minitab que la potencia del diseño para ambas variables de respuesta considerando este número de réplicas y este número de puntos centrales es mayor al 99%, por lo tanto se asume que la probabilidad de encontrar correctamente un efecto significativo es mayor al 99%. El diseño experimental se aplicó para el Caso 1 y después se toman los parámetros que brindan la máxima energía de esta instancia y se proponen para utilizarlos en las variantes del Caso 2. La Tabla 5.1 muestra los factores y niveles de factores considerados en el experimento. La Figura 5.1 muestra un fragmento del experimento realizado en Design-Expert. Cabe considerar que los experimentos se llevaron a cabo considerando computación en paralelo con 2 núcleos en una computadora con las siguientes especificaciones: Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz, 2701 Mhz, 2 procesadores principales, 4 procesadores lógicos y memoria física instalada (RAM) de 8GB.

Tabla 5. 1 Factores y niveles de los factores para el experimento

Nombre del factor	Tipo	Nivel bajo	Nivel alto
Método de cruzamiento	Catagórico	EQU	RAN
Método de selección	Catagórico	FIX	VAR
Elitismo	Catagórico	True	False
Tasa de mutación	Numérico	0.01	0.1
Número de iteraciones	Numérico	50	100

Std	Run	Factor 1 A:Crossover m	Factor 2 B:Selection me	Factor 3 C:Elitism	Factor 4 D:Mutation rate	Factor 5 E:Number of ite	Response 1 Power kwh	Response 2 CPU Time (sec)
1	44	EQU	FIX	False	0.01	50.00	16110.7	149.74
2	76	EQU	FIX	False	0.01	50.00	15937	96.28
3	100	EQU	FIX	False	0.01	50.00	16592.4	101.81
4	54	RAN	FIX	False	0.01	50.00	15763.2	91.39
5	24	RAN	FIX	False	0.01	50.00	16147.8	89.9
6	59	RAN	FIX	False	0.01	50.00	15936.8	87.4
7	21	EQU	VAR	False	0.01	50.00	16418.8	187.72
8	73	EQU	VAR	False	0.01	50.00	16198.5	157.68
9	92	EQU	VAR	False	0.01	50.00	16553.9	184.07
10	96	RAN	VAR	False	0.01	50.00	16160.1	198.8
11	49	RAN	VAR	False	0.01	50.00	16121.2	181.95
12	67	RAN	VAR	False	0.01	50.00	16457	166.48
13	40	EQU	FIX	True	0.01	50.00	16727.7	97.24
14	5	EQU	FIX	True	0.01	50.00	17171.9	97.3
15	19	EQU	FIX	True	0.01	50.00	17036.9	97.47
16	82	RAN	FIX	True	0.01	50.00	16766	114.49
17	25	RAN	FIX	True	0.01	50.00	16592.6	95.97
18	22	RAN	FIX	True	0.01	50.00	17036.8	150.42
19	27	EQU	VAR	True	0.01	50.00	17307.3	170.64
20	52	EQU	VAR	True	0.01	50.00	16727.8	203.47

Figura 5. 1 Fragmento del experimento 2⁵ con 3 réplicas y 8 puntos centrales

Por lo tanto, una vez realizando las 104 corridas totales del experimento se descubre que 5 corridas o arreglos de los parámetros logran alcanzar la máxima energía esperada para el Caso 1. La máxima energía esperada para el Caso 1 es de 17307.26 kWh. En la Tabla 5.2 se muestran las 5 corridas del experimento que logran la máxima energía esperada de la instancia del campo eólico con su respectivo tiempo computacional invertido. Nótese que las corridas estándar 61 y 62 corresponden a dos réplicas de las tres que se realizaron con ese arreglo de parámetros. Estas 5 corridas se proponen utilizar para optimizar las variantes de la instancia del Caso 2. Para optimizar las instancias correspondientes del Caso 2 se utiliza especialmente la corrida estándar 64 modificando la tasa de mutación a 0.006 con el objeto de que algoritmo realice una búsqueda eficiente.

Tabla 5.2 Arreglos de los factores que obtuvieron la máxima energía esperada para el Caso 1

Estándar	Corrida	Método de cruzamiento	Método de selección	Elitismo	Tasa de mutación	Número de iteraciones	Energía kWh	Tiempo de CPU (seg)
19	27	EQU	VAR	True	0.01	50	17307.26	170.64
61	45	EQU	FIX	True	0.01	100	17307.26	217.39
62	43	EQU	FIX	True	0.01	100	17307.26	213.64
64	26	RAN	FIX	True	0.01	100	17307.26	271.85
68	8	EQU	VAR	True	0.01	100	17307.26	352.23

Asimismo, como parte del experimento factorial desarrollado en Design Expert, se realiza el Análisis de Varianza (ANOVA por sus siglas en inglés) para cada una de las variables de respuesta consideradas: Energía y Tiempo de CPU. En la Figura 5.2 se presenta la tabla de ANOVA correspondiente a la variable de respuesta número 1: Energía kWh. El ANOVA muestra los factores y las interacciones que son significativas o que influyen sobre esta variable de respuesta. En este caso, todos los factores principales (A, B, C, D y E), así como

las interacciones CD, DE, BCD y ACDE resultan significativas. Además, se puede apreciar que no existe evidencia de curvatura en la región de experimentación.

En la Tabla 5.3 se presentan los valores de los principales estadísticos analizados correspondientes a la variable de respuesta 1. El estadístico R^2 es el coeficiente de determinación. En este caso, el valor de R^2 nos indica que el 67.32% de variabilidad en la Energía esta explicada por los factores que están incluidos en el modelo. El estadístico R^2 -adj es el coeficiente de determinación ajustado y es una medida para identificar si hemos incluido factores no significativos al modelo si difiere dramáticamente con el valor de R^2 . En este caso como los valores de R^2 y R^2 -adj no difieren significativamente entonces se comprueba que se han incluido los factores apropiados al modelo. El estadístico Adeq Precision es una medida de la cantidad de variación o ruido en el modelo, el valor deseado es que sea 4 o mayor. En este caso, el valor de Adeq Precision es de 11.504 lo cual nos indica que la cantidad de variación en el modelo correspondiente a la variable de respuesta 1 es mínima.

Response 1 Power kwh						
ANOVA for selected factorial model						
Analysis of variance table [Partial sum of squares - Type III]						
Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F	
Model	1.094E+007	9	1.215E+006	19.69	< 0.0001	significant
A-Crossover	6.233E+005	1	6.233E+005	10.10	0.0021	
B-Selection n	5.122E+005	1	5.122E+005	8.30	0.0050	
C-Elitism	3.086E+006	1	3.086E+006	49.99	< 0.0001	
D-Mutation ra	3.320E+006	1	3.320E+006	53.78	< 0.0001	
E-Number of	1.614E+006	1	1.614E+006	26.14	< 0.0001	
CD	1.000E+006	1	1.000E+006	16.21	0.0001	
DE	2.653E+005	1	2.653E+005	4.30	0.0411	
BCD	2.796E+005	1	2.796E+005	4.53	0.0362	
ACDE	4.302E+005	1	4.302E+005	6.97	0.0098	
Curvature	3.803E+005	8	47537.58	0.77	0.6299	not significant
Residual	5.309E+006	86	61731.28			
Lack of Fit	1.227E+006	22	55758.51	0.87	0.6258	not significant
Pure Error	4.082E+006	64	63784.42			
Cor Total	1.663E+007	103				

Figura 5. 2 ANOVA para la variable de respuesta 1: Energía

Tabla 5. 3 Estadísticos correspondientes a la variable de respuesta 1: Energía

R^2	.6732
R^2 -adj	.6390
Adeq Precision	11.504

De igual manera, se realiza el Análisis de Varianza para la variable de respuesta número 2: Tiempo de CPU. La Figura 5.3 muestra la tabla de ANOVA, la cual indica que los factores principales B y E, así como la interacción de los mismos influyen sobre el Tiempo de CPU invertido por el algoritmo. De igual manera, el ANOVA revela que no existe curvatura en la región de experimentación.

En la Tabla 5.4 se presentan los estadísticos de análisis correspondientes. En este caso, el estadístico R^2 indica que el 85.77% de variabilidad en el Tiempo de CPU esta explicada por los factores que están incluidos en el modelo. Debido a que el valor de R^2 y el valor de R^2 -adj no difieren dramáticamente, se asume que se han incluido los factores apropiados al modelo. Por último, el estadístico Adeq Precision contiene un valor de 27.805, lo cual nos indica que la cantidad de variación en el modelo es mínima.

Response 2		CPU Time (seconds)				
ANOVA for selected factorial model						
Analysis of variance table [Partial sum of squares - Type III]						
Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F	
Model	6.345E+005	3	2.115E+005	196.91	< 0.0001	significant
B-Selection n	2.462E+005	1	2.462E+005	229.22	< 0.0001	
E-Number of	3.319E+005	1	3.319E+005	309.00	< 0.0001	
BE	17670.31	1	17670.31	16.45	0.0001	
Curvature	3661.44	2	1830.72	1.70	0.1872	not significant
Residual	1.053E+005	98	1074.05			
Lack of Fit	33714.86	34	991.61	0.89	0.6420	not significant
Pure Error	71542.16	64	1117.85			
Cor Total	7.434E+005	103				

Figura 5. 3 ANOVA para la variable de respuesta 2: Tiempo de CPU

Tabla 5. 4 Estadísticos correspondientes a la variable de respuesta 2: Tiempo de CPU

R^2	.8577
R^2 -adj	.8534
Adeq Precision	27.805

5.1.1 Caso 1

La Tabla 5.5 muestra el código en R donde se declaran los valores correspondientes a las variables de entrada o parámetros del Caso 1 (véase Tabla 5.6) a través de la función *genAlgo*, la cual inicia un proceso de optimización con Algoritmos Genéticos.

Tabla 5. 5 Código que inicia una optimización de acuerdo a los parámetros de entrada del Caso 1

```
result <- genAlgo(Polygon1=Polygon1, GridMethod="r", n=12, Rotor=30, fcrR=3, iteration=100,
  vdirspe=data.in, crossPart1="EQU", selstate="FIX", mutr=0.01, Proportionality=1,
  SurfaceRoughness=0.14, topograp=FALSE, elitism=TRUE, nelit=6, trimForce=FALSE,
  referenceHeight=60, RotorHeight=60, Parallel=TRUE, numCluster=2)
```

La Tabla 5.6 muestra los valores de entrada correspondientes al Caso 1, el cual es propuesto por Gatscha (2016). Para solucionar el presente caso nótese que en la Tabla 5.6 se consideran los parámetros de la corrida estándar 61 que se presentó en la Tabla 5.2. La Figura 5.4 muestra las características y dimensiones del campo eólico a optimizar. En dicha figura se aprecia un campo eólico discreto con 36 cuadrículas, donde cada centroide de cada cuadrícula representa una posible localización de una turbina. La dimensión (resolución) de cada cuadrícula es de 90m x 90m. De acuerdo a la variable de entrada “n” que se especifica en la Tabla 5.6, las turbinas que se pretenden instalar en dicho campo eólico son 12. La Figura 5.5 corresponde a la rosa de los vientos de acuerdo a la información incluida en “data.in” que se encuentra en la Tabla 5.6. La información de “data.in” indica la dirección y velocidad con la que se propaga el viento considerado para el presente caso. Para este escenario, se considera un viento incidente con dirección uniforme a 0° (Norte-Sur) con una velocidad constante de 12 m/s.

Tabla 5. 6 Valores de entrada para el Caso 1

Variable de entrada	Valor
n (Número de turbinas a instalar)	12
SurfaceRoughness(metros)	0.14
Rotor Radius(metros)	30
fcrR(valor para el espaciado de la cuadrícula)	3
RotorHeight(metros)	60
referenceHeight(metros)	60
iteration	100
Proportionality	1
mutr(Tasa de mutación)	0.01
vdirspe(velocidad del viento y dirección)	data.in(12 m/s a 0°)
topograp	"FALSE"
elitism	"TRUE"
nelit	6
selstate	"FIX"
crossPart1	"EQU"
trimForce	"FALSE"

Resolution: 90 m and prop: 1
Total Area: 0.454 km²
Number Grids: 36
Sum Grid size: 0.292 km²

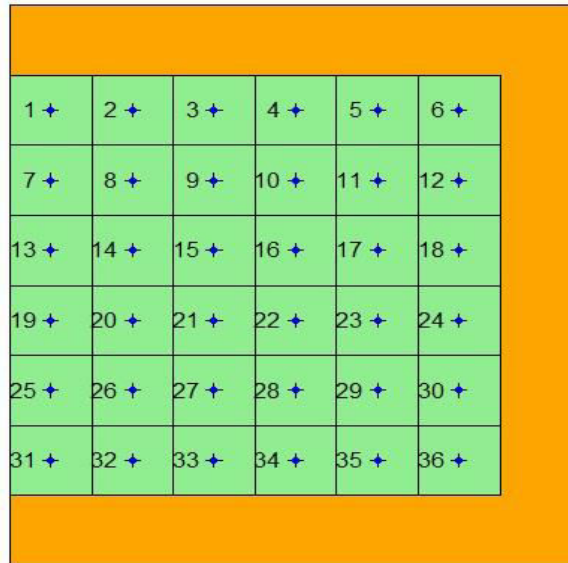


Figura 5. 4 Características y dimensiones del campo eólico a optimizar




Figura 5. 5 Rosa de los vientos para el Caso 1

Por lo tanto, considerando todo lo anteriormente descrito, la mejor solución de distribución para el presente caso se muestra en la Figura 5.6. Esta solución se considera la mejor posible debido a que no existe otro diseño o distribución del campo eólico que brinde una mayor cantidad total de energía. Por lo tanto, esta solución se considera como la mejor solución de distribución para el Caso 1. De igual forma, en la Figura 5.6 se pueden apreciar los puntos dentro de las cuadrículas donde se ubican instalados los aerogeneradores de acuerdo a la solución óptima encontrada. Los colores y los valores que se presentan debajo de estos puntos indican la pérdida de energía ocasionada por los efectos estela. Los puntos donde los déficits de energía ocasionados por los efectos estela son débiles se representan en color verde, mientras que los puntos donde los déficits de energía provocados por los efectos estela son altos se presentan de color rojo. Asimismo, la Figura 5.6 también muestra la distancia mínima y la distancia promedio a la que se encuentran todas las turbinas de acuerdo a la solución encontrada. El tiempo de CPU que el algoritmo invirtió para encontrar tal solución utilizando computación en paralelo con 2 núcleos fue de 227.67 segundos.

En la Figura 5.7 se aprecia que en la iteración número 61 el algoritmo convergió hacia la mejor solución posible. La Figura 5.8 muestra el vector solución o individuo mejor evaluado para el Caso 1, el cual concuerda con la mejor distribución de aerogeneradores presentada en la Figura 5.6. En dicho vector se puede apreciar un cromosoma o individuo de 36 posiciones, cada una de estas posiciones representa un centroide o una posible ubicación de una turbina, por lo que en total se tiene un vector solución con 12 1's, lo cual representa el número total de turbinas que se pretendían instalar.

La Figura 5.9 muestra la misma solución encontrada por el algoritmo desde una perspectiva más real o parecida a un campo eólico. En dicha figura también se puede apreciar que las turbinas sombreadas de color verde son aquellas que son afectadas en menor medida por los efectos estela, mientras que aquellas sombreadas en color rojo son afectadas en mayor medida por los efectos estela.

La Figura 5.10 informa el progreso de la cantidad de energía producida en cada una de las generaciones. En dicha figura, el valor de energía máxima alcanzados por un individuo en cada generación se representa en color verde, los valores de energía promedio en azul y los valores mínimos de energía en rojo.

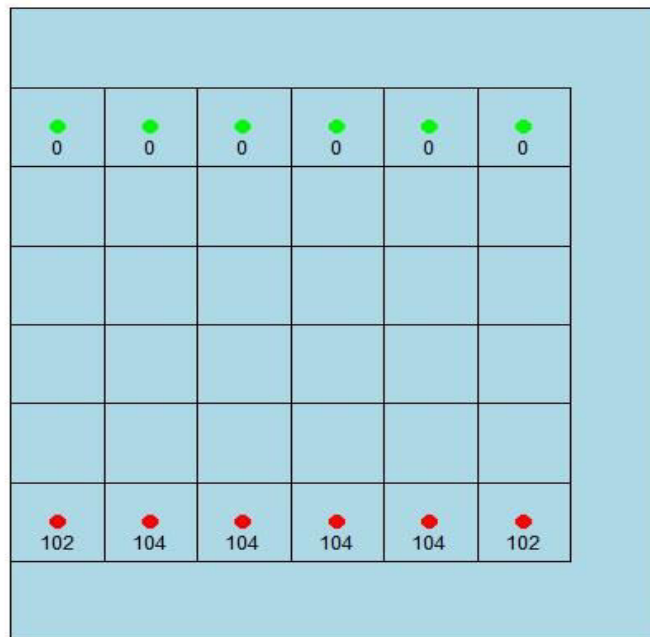
La Figura 5.11 indica la cantidad de individuos de cada población a lo largo de todas las generaciones. Las cantidades de individuos se cuentan después de la función de aptitud, selección y cruce. La cantidad de individuos en cada iteración es la misma tanto para la función de aptitud y la función de cruce. Los puntos negros representan el número de individuos después de la función de aptitud, los puntos rojos la cantidad de individuos después de la función de selección y los puntos verdes indican la cantidad de individuos una vez que se ha realizado el cruce.

La Figura 5.12 muestra la evolución de las eficiencias energéticas del campo eólico durante todas las generaciones o iteraciones. Los valores máximos de eficiencia energética encontrados se representan en verde, los valores promedio en azul y los valores mínimos en rojo. De igual manera, dicha figura muestra la influencia de la mutación de acuerdo a los valores de eficiencia energética. Las líneas negras verticales indican en que iteraciones se utilizó la tasa de mutación variable en lugar de la tasa de mutación fija. En este caso, el algoritmo recurrió en 7 ocasiones a la tasa de mutación variable para explorar otros rincones del espacio de soluciones.

La Figura 5.13 muestra la evolución de las eficiencias energéticas del campo eólico durante todas las generaciones y se trazan líneas verticales verdes para las generaciones en las que el porcentaje de selección fue mayor al 75%. De acuerdo a la Figura 5.11, algunas iteraciones tenían una cantidad de individuos bastante baja, es decir menos de 20 individuos debido a que el algoritmo remueve en cada iteración 4 de los peores individuos. Además, en dicha figura se aprecia que para evitar la extinción de la población, el algoritmo seleccionó en 8 ocasiones el 100% de los individuos para después cruzarlos y crear más individuos.

La Figura 5.14 muestra las eficiencias energéticas para cada una de las generaciones y se trazan líneas verticales rojas para las generaciones en las que el número de partes cruzadas fue mayor que 2. De acuerdo a la figura, en 5 ocasiones el algoritmo utilizó 3 partes cruzadas con la misma finalidad de evitar la extinción de la población. Esto fue suficiente, ya que de acuerdo a la Figura 5.11 una vez que se incrementó el número de puntos de cruce, el tamaño de la población aumentó rápidamente tal como sucedió en la iteración $t=48$.

Best Energy: 1
Energy Output 17307.26 kW
Efficiency: 81.27



minimal Distance 90
 mean Distance 366.56

Figura 5. 6 Mejor solución encontrada por el algoritmo

61 Round
Best Energy Output: 17307.26 W/h
Efficiency: 81.27 %




Figura 5. 7 Mejor solución encontrada desde la iteración 61

Position of the gene	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	
Value(ID)	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1

Figura 5. 8 Vector solución que representa la mejor solución



Figura 5. 9 Representación alternativa del diseño óptimo del campo eólico

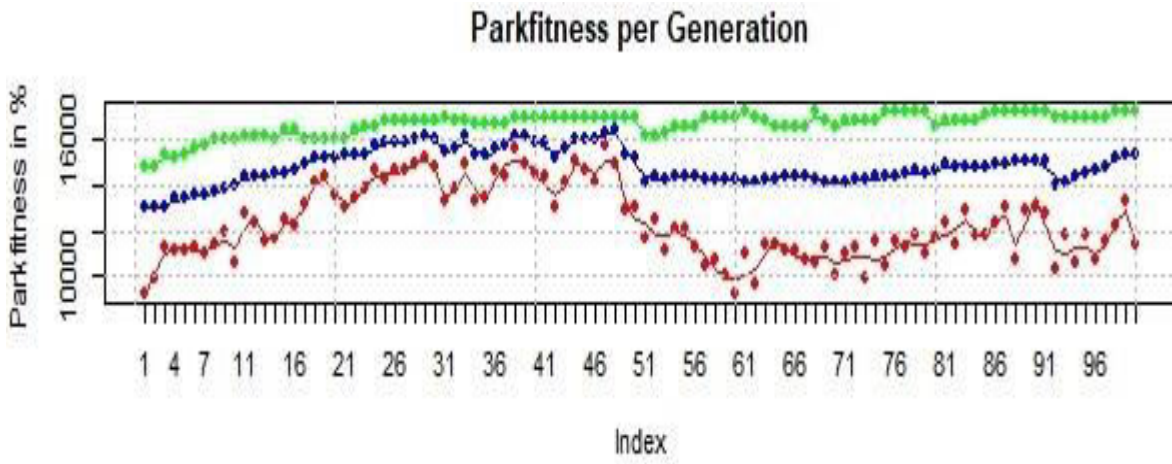


Figura 5. 10 Progreso de los valores de aptitud en cuanto a energía




Figura 5. 11 Cantidad de individuos en cada iteración




Figura 5. 12 Influencia de la mutación variable en los valores de eficiencia energética




Figura 5. 13 Influencia de la selección de individuos en los valores de eficiencia energética




Figura 5. 14 Influencia del cruce de individuos con 3 partes de cruce

5.1.2 Caso 2

El Caso 2 corresponde a un problema de optimización propuesto por Gatscha (2016). Las características y dimensiones del campo eólico que se trata en la presente subsección se

consideran en las variantes correspondientes al Caso 2: Caso 2(a), Caso 2(b) y Caso 2(c). Al inicio de cada variante se describen las modificaciones pertinentes en las variables de entrada o parámetros. El campo eólico considerado en las variantes del Caso 2 consiste en un área total de 2km x 2km, el cual se divide en 100 cuadrículas cada una con una resolución de 200m x 200m tal como se muestra en la Figura 5.15 La Figura 5.16 corresponde a la rosa de los vientos, la cual muestra la dirección y velocidad con la que se propaga el viento considerado en las variantes del Caso 2. Para estos casos, se considera un viento incidente con dirección uniforme a 0° (Norte-Sur) con una velocidad constante de 12 m/s.

Resolution: 200 m and prop: 0.99
Total Area: 4 km²
Number Grids: 100
Sum Grid size: 4 km²




Figura 5. 15 Características y dimensiones del campo eólico




Figura 5. 16 Rosa de los vientos utilizada para las variantes del Caso 2

5.1.2.1 Caso 2(a)

De acuerdo a los valores de entrada incluidos en la Tabla 5.7 y los datos del campo eólico expuestos en la subsección 5.1.2 se optimiza la presente variante del Caso 2. Nótese que en la Tabla 5.7 se presentan los parámetros correspondientes a la corrida estándar número 64 mostrada en la Tabla 5.2. Para brindar una solución de mayor calidad a esta instancia se decide usar una tasa de mutación de 0.006 en lugar de 0.01. Esto debido a que el experimento arrojó que mientras más pequeña sea la tasa de mutación el algoritmo encuentra mejores soluciones. Por lo tanto, se propuso usar una tasa de mutación de 0.006, observando que efectivamente con esta tasa de mutación el algoritmo es capaz de explorar soluciones remotas dentro del espacio de soluciones y converger hacía soluciones de muy alta calidad. La Figura 5.17 muestra la mejor solución encontrada por el algoritmo para esta variante del Caso 2. El tiempo de CPU que el algoritmo invirtió para encontrar dicha solución fue de 204.83 segundos (3.4138 minutos de CPU), haciendo uso de la computación en paralelo con 2 núcleos. Gatscha (2016) reporta una solución de 75605.96 kW, con una eficiencia de 79.88% y un tiempo computacional invertido de una hora y media. La comparación entre el tiempo que tardó el algoritmo para encontrar la solución que en esta investigación se reporta y la reportada por Gatscha (2016) no es posible realizarse directamente debido a que en Gatscha (2016) no se especifica si el tiempo corresponde al tiempo real que invirtió la computadora o al tiempo en CPU. Sin embargo, si es posible realizar una comparación entre la calidad de las soluciones: la solución energética que se reporta en esta investigación supera por 720.02 unidades de energía en kW a la solución reportada por Gatscha (2016), lo cual equivale a un incremento del 0.76% en la eficiencia. De acuerdo a la Figura 5.17, la distribución de aerogeneradores encontrada en esta investigación es diferente a la distribución reportada por Gatscha (2016).

La Figura 5.18 muestra la mejor solución encontrada por el algoritmo desde una perspectiva más semejante a un campo eólico.

En la Figura 5.19 se presenta el desarrollo de las eficiencias energéticas del campo eólico durante todas las generaciones. En dicha figura se aprecia la evolución de las eficiencias en cada generación, las cuales mantienen una tendencia positiva incremental sobre todo para las eficiencias máximas y promedio representadas en color verde y azul respectivamente.

Asimismo, se aprecia que aproximadamente en la iteración t=90 el algoritmo converge hacia la mejor solución.

Tabla 5. 7 Valores de entrada para el Caso 2(a)

Variable de entrada	Valor
n (Número de turbinas a instalar)	30
SurfaceRoughness(metros)	0.3
Rotor Radius(metros)	40
fcrR(valor para el espaciado de la cuadrícula)	5
RotorHeight(metros)	60
referenceHeight(metros)	60
iteration	100
Proportionality	0.99
mutr(Tasa de mutación)	0.006
vdirspe(velocidad del viento y dirección)	data.in(12 m/s a 0°)
topograp	“FALSE”
elitism	“TRUE”
nelit	7
selstate	“FIX”
crossPart1	“RAN”
trimForce	“TRUE”




Figura 5. 17 Mejor distribución del campo eólico




Figura 5. 18 Representación alternativa de la distribución óptima del campo eólico




Figura 5. 19 Evolución de las eficiencias durante todas las generaciones

5.1.2.2 Caso 2(b)


Para optimizar la segunda variante del Caso 2 se utilizaron los mismos valores de entrada de la Tabla 5.7, excepto el número de iteraciones. Para este caso, el algoritmo se ejecuta con 300 iteraciones tal como se realiza en Gatscha (2016). El objetivo de utilizar 300 iteraciones de acuerdo a Gatscha (2016) se basa en la premisa de que si el algoritmo se ejecutara con una cantidad elevada de iteraciones, este podría brindar soluciones superiores debido a que la tasa de mutación variable se activaría con más frecuencia.

La Figura 5.20 muestra la mejor solución encontrada al ejecutar el algoritmo durante 300 iteraciones. El tiempo de CPU invertido para encontrar dicha solución fue de 742.74 segundos (12.379 minutos) utilizando computación en paralelo con 2 núcleos. Gatscha (2016) reporta una solución de 76516.77 kW y una eficiencia del 80.85% al ejecutar el algoritmo durante 300 iteraciones. De acuerdo a Gatscha (2016), el tiempo computacional invertido por el algoritmo para encontrar dicha solución fue de 5 horas. La solución energética que se reporta en la presente investigación supera por 437.3 unidades de energía en kW a la solución reportada por Gatscha (2016), lo cual equivale a un incremento del 0.46% en la eficiencia energética. La localización de aerogeneradores correspondiente a la solución reportada por Gatscha (2016) difiere con la distribución resultante que en esta investigación se reporta.

La Figura 5.21 muestra la mejor solución encontrada desde un panorama más parecido a un campo eólico.

En la Figura 5.22 se expone la evolución de las eficiencias energéticas en porcentaje durante todas las generaciones. En dicha figura se aprecia que aproximadamente en la iteración $t=254$ el algoritmo convergió hacia la mejor solución, después explora otros espacios de soluciones donde encuentra soluciones de menor calidad para nuevamente converger en la mejor solución a partir de la iteración $t=275$ hasta $t=278$.

Best Energy: 1
Energy Output 76954.07 kW
Efficiency: 81.31



minimal Distance 200
 mean Distance 1191.74

Figura 5. 20 Mejor distribución del campo eólico




Figura 5. 21 Representación alternativa de la solución




Figura 5. 22 Evolución de las eficiencias energéticas del campo eólico por generación

5.1.2.3 Caso 2(c)

El presente caso se optimizó de igual modo considerando los datos del campo eólico expuestos en la subsección 5.1.2 y los valores de entrada que se muestran en la Tabla 5.7, excepto el valor del radio del rotor y el valor de $fcrR$. Por lo tanto, en esta optimización se considera un radio del rotor de 20m para todas las turbinas, así como se considera un valor de $fcrR$ de 10.

La Figura 5.23 muestra la mejor solución encontrada por el algoritmo para la presente variante del Caso 2. El tiempo de CPU que el algoritmo invirtió para encontrar la solución que se muestra en la Figura 5.23 fue de 287.64 segundos (4.794 minutos de CPU), utilizando computación en paralelo con 2 núcleos. De igual manera, Gatscha (2016) resuelve el presente caso usando turbinas con rotores de radio de 20m y un valor de $fcrR$ de 10. Por lo tanto, Gatscha (2016) reporta una solución de 21585.1 kW y una eficiencia de 91.23%. El tiempo computacional que se invirtió para obtener dicha solución no se reporta. La solución energética que se reporta en esta investigación supera por 11.96 unidades de energía en kW a la solución reportada por Gatscha (2016), lo cual equivale a un incremento del 0.05% en la

eficiencia energética. De acuerdo a la Figura 5.23, la distribución de aerogeneradores que se encuentra en esta investigación difiere a la distribución reportada por Gatscha (2016).

La Figura 5.24 exhibe la evolución de las eficiencias energéticas correspondientes a la optimización del presente caso. Asimismo, en dicha figura se aprecia que se mantiene una tendencia incremental de las eficiencias conforme el algoritmo va avanzando en las generaciones, sin embargo se puede notar que en algunas iteraciones sobre todo después de la iteración $t=80$ el algoritmo encuentra soluciones de menor calidad para converger nuevamente hacia la mejor solución que previamente había encontrado.




Figura 5. 23 Mejor distribución del campo eólico




Figura 5. 24 Evolución de las eficiencias del campo eólico por generación

5.1.3 Caso 3

El presente caso se obtuvo de Fischetti & Monaci (2016). La Tabla 5.8 muestra los valores de entrada correspondientes a este caso. La Tabla 5.8 muestra algunos valores de entrada con los que el algoritmo realiza una búsqueda eficiente de soluciones de acuerdo al DOE presentado al inicio de este capítulo. En Fischetti & Monaci (2016), este problema práctico o instancia se resuelve contemplando 25 turbinas, sin embargo, en este trabajo de tesis se consideran las variables de entrada tal como en Fischetti & Monaci (2016) excepto el número de turbinas. Esto con la intención de realizar un análisis comparativo en cuanto a rendimiento; eficiencia del campo eólico, energía total producida y déficit total de energía de acuerdo al número de turbinas a instalar. Además del análisis comparativo al variar el número de turbinas, el escenario del presente caso se utiliza para identificar la mejor distribución de turbinas encontrada por el algoritmo considerando diferentes direcciones de viento, estos resultados se presentan después del análisis comparativo. La Figura 5.25 muestra las dimensiones y características del campo eólico propuestas en Fischetti & Monaci (2016). La Figura 5.26 muestra la dirección del viento propuesta en Fischetti & Monaci (2016). Esta dirección de viento incidente se considera solamente para realizar el análisis comparativo que corresponde al rendimiento del campo eólico de acuerdo al número de turbinas instaladas.

Tabla 5. 8 Valores de entrada para el Caso 3

Variable de entrada	Valor
n (Número de turbinas a instalar)	25
SurfaceRoughness(metros)	0.0002
Rotor Radius(metros)	30
fcrR(valor para el espaciado de la cuadrícula)	10
RotorHeight(metros)	60
referenceHeight(metros)	60
iteration	100
Proportionality	0.99
mutr(Tasa de mutación)	0.006
vdirspe(velocidad del viento y dirección)	data.in(12 m/s a 45°)
topograp	“FALSE”
elitism	“TRUE”
nelit	7
selstate	“FIX”
crossPart1	“RAN”
trimForce	“TRUE”

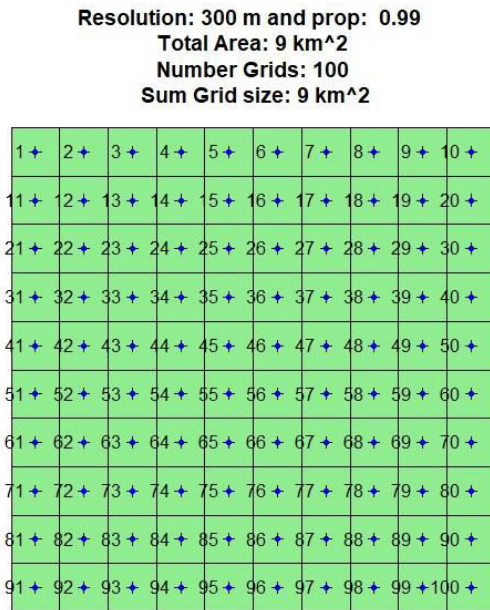


Figura 5. 25 Campo eólico a optimizar

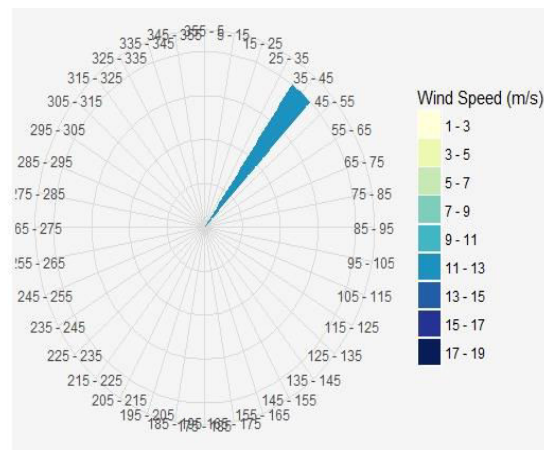


Figura 5. 26. Dirección del viento considerada para el análisis comparativo

5.1.3.1 Análisis comparativo de rendimiento de campos eólicos de acuerdo al número de turbinas instaladas

La Tabla 5.9 presenta el análisis comparativo de rendimiento de acuerdo al número de turbinas. Por ejemplo, la instancia #1 corresponde a un campo eólico con 40 turbinas a instalar y el cual produce 66,715.61 kWh de energía total con una eficiencia del 93.99% y un

déficit total de energía de 4615 kWh debido a los efectos estela. La Tabla 5.9 también presenta el tiempo de CPU que la computadora invirtió para que el algoritmo encontrara la mejor solución de rendimiento en cada instancia. El tiempo computacional que se invirtió para que el algoritmo encontrara la mejor solución de distribución correspondiente a la instancia #1 (es decir, con 40 turbinas) fue de 262.76 segundos.

Tabla 5. 9 Análisis comparativo de rendimiento de acuerdo al número de turbinas instaladas

Núm. de instancia	Núm. de turbinas	Energía total producida (kWh)	Eficiencia del campo eólico (%)	Déficit de energía (efecto estela, kWh)	Tiempo de CPU (seg)
1	40	66,715.61	93.99	4615	262.76
2	37	62,413.02	95.06	3871	287.23
3	35	59,355.79	95.56	2657	221.11
4	33	56,567.17	96.59	2834	226.06
5	31	53,241.68	96.78	2140	468.52
6	29	50,269.28	97.68	1695	266.80
7	27	46,981.25	98.05	1348	305.23
8	25	43,832.63	98.8	1063	243.50
9	23	40,445.79	99.09	805	447.49
10	21	37,072.73	99.48	482	694.78
11	19	33,688.23	99.91	45	312.22
12	17	30,167.95	100	0	485.25

La Figura 5.27 muestra la mejor distribución del campo eólico al instalar 40 aerogeneradores. Como bien se comentó, el tiempo computacional invertido para encontrar esta solución fue

de 262.76 segundos. La Figura 5.28 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 27. Mejor solución de distribución para la instancia #1: 40 aerogeneradores




Figura 5. 28. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #1

La Figura 5.29 muestra la mejor distribución del campo eólico al instalar 37 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 287.23 segundos. La Figura 5.30 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 29. Mejor solución de distribución para la instancia #2: 37 aerogeneradores




Figura 5. 30. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #2

La Figura 5.31 muestra la mejor distribución del campo eólico al instalar 35 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 221.11 segundos. La Figura 5.32 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 31. Mejor solución de distribución para la instancia #3: 35 aerogeneradores




Figura 5. 32. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #3

La Figura 5.33 muestra la mejor distribución del campo eólico al instalar 33 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 226.06 segundos. La

Figura 5.34 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 33. Mejor solución de distribución para la instancia #4: 33 aerogeneradores




Figura 5. 34. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #4

La Figura 5.35 muestra la mejor distribución del campo eólico al instalar 31 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 468.52 segundos. La

Figura 5.36 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.

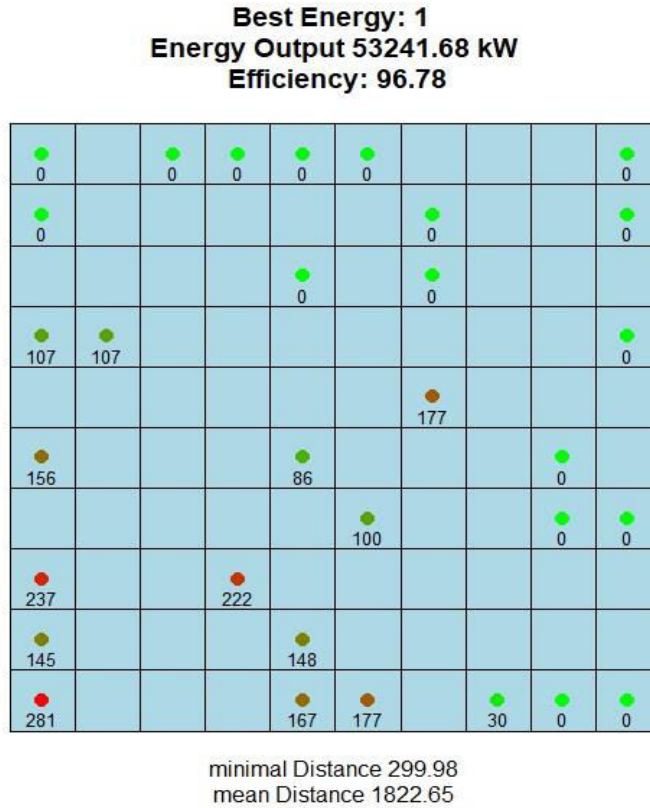


Figura 5. 35. Mejor solución de distribución para la instancia #5: 31 aerogeneradores




Figura 5. 36. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #5

La Figura 5.37 muestra la mejor distribución del campo eólico al instalar 29 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 266.80 segundos. La Figura 5.38 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 37. Mejor solución de distribución para la instancia #6: 29 aerogeneradores




Figura 5. 38. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #6

La Figura 5.39 muestra la mejor distribución del campo eólico al instalar 27 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 305.23 segundos. La Figura 5.40 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 39. Mejor solución de distribución para la instancia #7: 27 aerogeneradores




Figura 5. 40. Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #7

La Figura 5.41 muestra la mejor distribución del campo eólico al instalar 25 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 243.50 segundos. La Figura 5.42 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 41 Mejor solución de distribución para la instancia #8: 25 aerogeneradores




Figura 5. 42 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #8

La Figura 5.43 muestra la mejor distribución del campo eólico al instalar 23 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 447.49 segundos. La Figura 5.44 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 43 Mejor solución de distribución para la instancia #9: 23 aerogeneradores




Figura 5. 44 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #9

La Figura 5.45 muestra la mejor distribución del campo eólico al instalar 21 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 694.78 segundos. La Figura 5.46 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 45 Mejor solución de distribución para la instancia #10: 21 aerogeneradores




Figura 5. 46 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #10

La Figura 5.47 muestra la mejor distribución del campo eólico al instalar 19 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 312.22 segundos. La Figura 5.48 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 47 Mejor solución de distribución para la instancia #11: 19 aerogeneradores




Figura 5. 48 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #11

La Figura 5.49 muestra la mejor distribución del campo eólico al instalar 17 aerogeneradores. El tiempo computacional invertido para encontrar esta solución fue de 485.25 segundos. La Figura 5.50 muestra el progreso de las eficiencias energéticas por generación correspondiente a esta corrida de optimización.




Figura 5. 49 Mejor solución de distribución para la instancia #12: 17 aerogeneradores




Figura 5. 50 Evolución de las eficiencias energéticas correspondiente a la corrida de optimización de la instancia #12

La Figura 5.51 muestra un análisis de regresión de acuerdo a los resultados presentados en la Tabla 5.9. Dicho análisis corresponde a la relación entre el número de turbinas instaladas y la cantidad de energía total producida en kWh. Por lo tanto, la gráfica muestra que existe un comportamiento lineal entre el número de turbinas instaladas y la cantidad de energía total producida en kWh, es decir, mientras más turbinas se instalen en un campo eólico la energía total esperada será mayor. En la gráfica también se puede observar la ecuación de regresión respecto a estas dos variables, donde la variable independiente x = número de turbinas instaladas. La variable dependiente en este caso es la cantidad de energía producida. El coeficiente de determinación (R^2) para esta relación es del 0.9991.




Figura 5. 51. Gráfico de análisis de regresión: Núm. de turbinas-Energía

De la misma forma, se realizó un análisis de regresión entre el número de turbinas instaladas y la cantidad de energía pérdida (déficit) debido a los efectos estela. La Tabla 5.9 muestra los datos resultantes de la relación entre estas dos variables. La Figura 5.52 muestra el gráfico correspondiente a este análisis de regresión. Por lo tanto, dicho gráfico exhibe un comportamiento polinómico de segundo grado entre el número de turbinas instaladas y la cantidad de energía pérdida en kWh. La Figura 5.52 también muestra la ecuación de regresión respecto a estos dos factores, donde la variable x = número de turbinas instaladas. El coeficiente de determinación (R^2) para esta relación es del 0.9853. Cabe destacar que se decidió manejar como comportamiento polinómico debido a que el valor de determinación o R^2 fue el más cercano a uno en comparación a otros modelos.





Figura 5. 52. Gráfico de análisis de regresión: Núm. de turbinas-Déficit de energía

5.1.3.2 Análisis de distribución de aerogeneradores de acuerdo a la dirección del viento incidente

Considérese que las características y dimensiones del campo eólico así como las variables de entrada declaradas en el inicio de la presente sección se utilizaron para todas las optimizaciones que a continuación se presentan, solamente la dirección del viento se varió para cada escenario. La Figura 5.53 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente de Norte-Sur (0°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 243.61 segundos. La Figura 5.54 muestra la dirección del viento incidente considerado en esta optimización.

Best Energy: 1
Energy Output 41726.18 kW
Efficiency: 94.05



minimal Distance 300
 mean Distance 1794.17




Figura 5. 54 Viento incidente a 0°

Figura 5. 53 Mejor solución de distribución con viento a 0°

La Figura 5.55 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente de Noreste (45°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 272.56 segundos. La Figura 5.56 muestra la dirección del viento incidente considerado en esta optimización.

La Figura 5.57 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente del Este (90°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 199.89 segundos. La Figura 5.58 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 55 Mejor solución de distribución con viento proveniente del Noreste




Figura 5. 56 Viento incidente del Noreste




Figura 5. 57 Mejor solución de distribución con viento a 90°




Figura 5. 58 Viento incidente a 90°

La Figura 5.59 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente del Sureste (135°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 304.22 segundos. La Figura 5.60 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 59 Mejor solución de distribución con viento a 135°




Figura 5. 60 Viento incidente a 135°

La Figura 5.61 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente de Sur-Norte (180°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 438.47 segundos. La Figura 5.62 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 61 Mejor solución de distribución con viento a 180°




Figura 5. 62 Viento incidente a 180°

La Figura 5.63 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente del Suroeste (225°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 367.58 segundos. La Figura 5.64 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 63 Mejor solución de distribución con viento proveniente del Suroeste




Figura 5. 64 Viento incidente del Suroeste

La Figura 5.65 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente del Oeste (270°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 277.98 segundos. La Figura 5.66 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 65 Mejor solución de distribución con viento proveniente del Oeste




Figura 5. 66 Viento incidente del Oeste

La Figura 5.67 muestra la mejor solución de distribución encontrada por el algoritmo al considerar un viento incidente del Noroeste (315°) con una velocidad de 12 m/s. El tiempo computacional invertido para encontrar esta solución fue de 296.05 segundos. La Figura 5.68 muestra la dirección del viento incidente considerado en esta optimización.




Figura 5. 67 Mejor solución de distribución con viento proveniente del Noroeste




Figura 5. 68 Viento incidente del Noroeste

La Tabla 5.10 muestra el resumen de los resultados de rendimiento del campo eólico al variar las direcciones de viento. Por ejemplo, la instancia #1 corresponde al campo eólico cuya dirección del viento proviene del Norte (0°) y el cual produce 41,726.18 kWh de energía total con una eficiencia del 94.05% y un déficit total de energía de 2000 kWh debido a los efectos estela. La Tabla 5.10 también presenta el tiempo de CPU que la computadora invirtió para que el algoritmo encontrara la mejor solución de rendimiento en cada instancia. El tiempo computacional que invirtió el algoritmo para encontrar la mejor solución de distribución (Figura 5.53) correspondiente a la instancia #1 (es decir, considerando la dirección del viento a 0°) fue de 243.61 segundos.

Tabla 5. 10 Tabla resumen de los resultados de rendimiento del campo eólico al variar las direcciones de viento

Núm. de instancia	Dirección del viento	Energía total producida (kWh)	Eficiencia del campo eólico (%)	Déficit de energía (efecto estela, kWh)	Tiempo de CPU (seg)
1	0°	41,726.18	94.05	2000	243.61
2	45°	43,603.05	98.28	731	272.56
3	90°	41,948.2	94.55	2000	199.89
4	135°	43,724.59	98.56	1027	304.22
5	180°	41,684.53	93.96	2000	438.47
6	225°	43,804.81	98.74	1045	367.58
7	270°	41,961.48	94.58	2000	277.98
8	315°	43,746.45	98.61	1125	296.05

La Figura 5.69 muestra un análisis de regresión en base a los resultados presentados en la Tabla 5.10. Dicho análisis corresponde a la relación entre la dirección del viento incidente y la cantidad de energía total producida en kWh. En dicha figura se puede observar que existe

un comportamiento oscilante entre la dirección del viento incidente y la cantidad de energía total producida en kWh. Por lo tanto, se asume que la energía total que podría producir un campo eólico no depende de la dirección del viento incidente.




Figura 5. 69. Gráfico de análisis de regresión: Dirección del viento-Energía

Del mismo modo y de acuerdo a los resultados presentados en la Tabla 5.10, se realizó un análisis de regresión entre la dirección del viento y la cantidad de energía pérdida (déficit) debido a los efectos estela. La Figura 5.70 muestra el gráfico correspondiente a este análisis de regresión. Por lo tanto, dicho gráfico exhibe un comportamiento fluctuante entre la dirección del viento incidente y la cantidad de energía pérdida en kWh, por lo que podemos atribuir que las pérdidas de energía que un campo eólico podría manifestar debido a los efectos estela son independientes a la dirección del viento incidente.




Figura 5. 70. Gráfico de análisis de regresión: Dirección del viento-Déficit de energía (efecto estela)

5.1.4 Resolución del problema de optimización del diseño de campos eólicos utilizando un método numérico. Comparación de resultados; Algoritmo Genético vs Algoritmo GRG Non-linear

Se utiliza el algoritmo o método numérico GRG Non-linear (Gradiente Reducido Generalizado) para resolver el problema de optimización del diseño de campos eólicos y los resultados se comparan con los obtenidos por el método Evolutivo (Algoritmos Genéticos o GA por sus siglas en inglés). El algoritmo GRG es uno de los métodos de programación no lineal más robustos para resolver problemas no lineales. Se utilizó el Solver de Excel que incluye ambos métodos para resolver las mismas instancias del problema considerando el Modelo de Jensen a través de la programación del mismo en Excel. Los resultados comparativos de las instancias se presentan en la Tabla 5.11. En el caso de optimización con GA se decidió replicar el proceso tres veces con la finalidad de estimar mejor el esfuerzo computacional (tiempo de ejecución) debido a que se observó que el algoritmo evolutivo invertía menor tiempo computacional a medida que se resolvían instancias más grandes (más turbinas y mayor número de posibles localizaciones). Todas las instancias se resolvieron con un viento incidente con dirección Norte-Sur y una velocidad constante de 12.8 m/s. Para la optimización de cada una de las instancias se utilizó un solo tipo de turbina con las siguientes características técnicas: altura de 60 m, diámetro del rotor de 40 m y un coeficiente de empuje constante de 0.88. La Figura 5.71 muestra la curva de potencia de la turbina utilizada. Las

corridas de optimización se realizaron en una computadora con las mismas especificaciones técnicas descritas en la sección 5.1 de resultados. La Tabla 5.12 exhibe los valores de los parámetros en los cuales se ajustaron los algoritmos para la optimización de todas las instancias. Nótese que algunos parámetros permanecieron ajustados de acuerdo a los valores predeterminados del Solver de Excel 2013. La curva de potencia presentada en la Figura 5.71 se representa a través de las siguientes expresiones (la velocidad del viento U está expresada en m/s y la energía en kW):

$$P(U) = \begin{cases} 0 & \text{para } U < 2 \\ 0.3U^3 & \text{para } 2 \leq U < 12.8 \end{cases} \quad (5.1)$$

$$P(U) = \begin{cases} 0.3U^3 & \text{para } 2 \leq U < 12.8 \\ 629.1 & \text{para } 12.8 \leq U < 18 \end{cases} \quad (5.2)$$

$$P(U) = \begin{cases} 629.1 & \text{para } 12.8 \leq U < 18 \\ 0 & \text{para } 18 \leq U \end{cases} \quad (5.3)$$

$$P(U) = \begin{cases} 0 & \text{para } 18 \leq U \end{cases} \quad (5.4)$$




Figura 5. 71 Curva de potencia de la turbina utilizada para la comparación de algoritmos

Tabla 5. 11 Comparación de resultados entre el método numérico GRG Non-linear y la metaheurística evolutiva

Núm. de instancia	Tamaño de la instancia (Número de cuadrículas)	Distancia entre cuadrículas (metros)	Número de turbinas a instalar	Dimensiones del campo eólico (mts*mts)	Mejores valores objetivos por GA y tiempos de ejecución (kWh, segundos)			Mejor valor objetivo por GRG y tiempo de ejecución (kWh, segundos)
					Réplica 1	Réplica 2	Réplica 3	
1	3*4	500	8	1500*2000	4992.88,22.125	4992.88,20.48	4992.88,19.92	4992.88,48.656
2	4*4	200	8	800*800	4641.48,36.578	4641.48,37.46	4641.48,38.23	4641.48,164.328

3	5*5	200	15	1000*1000	7523.41,45.25	7523.41,50.34	7523.41,52.45	7523.41,443.062
4	6*6	200	12	1200*1200	7298.30,36.219	7298.30,35.96	7219.01,36.12	7318.26,2780.75
5	6*10	200	20	1200*2000	12018.56,33.87	11879.93,35.1	11979.18,36.1	12197.10,8910.54
6	7*7	200	21	1400*1400	11533.05,34.94	11578.07,36.0	11488.28,36.3	11818.92,18065.11
7	7*10	200	30	1400*2000	16229.16,44.60	16379.59,36.2	16204.03,36.5	16884.17,60268.62

Tabla 5. 12 Valores de los parámetros utilizados en el Solver de Excel

Parámetro/Método	GA	GRG Non-linear
Convergencia	0.0000001	0.000001
Optimalidad de entero (%)	0	0
Tiempo máximo (segundos)	Ilimitado	Ilimitado
Iteraciones	Ilimitado	Ilimitado
Precisión de restricciones	0.000001	0.000001
Máximo de sub problemas	Ilimitado	Ilimitado
Máximo de soluciones viables	Ilimitado	Ilimitado
Método de derivados	-	Central
Inicio múltiple	-	Verdadero
Tasa de mutación	0.075	-
Tamaño de la población	100	100
Valor de inicialización	0	0
Tiempo máximo sin mejora (segundos)	30	-

La Figura 5.72 muestra los tiempos de ejecución que el Algoritmo Genético invirtió para resolver cada una de las instancias propuestas en esta comparación de algoritmos. El proceso de optimización fue replicado tres veces para cada instancia utilizando GA. Asimismo, la Figura 5.72 indica el promedio aritmético de los tiempos de ejecución, el cual se obtuvo a partir de las 3 réplicas. La tendencia que presenta esta gráfica indica que aunque el número de variables aumenta (más número de turbinas a instalar y mayor número de posibles localizaciones) el algoritmo es capaz de encontrar soluciones de buena calidad en tiempos de cómputo razonables.




Figura 5. 72 Tiempos de ejecución y promedio aritmético para cada instancia

La Figura 5.73 muestra los tiempos de ejecución que el algoritmo GRG invirtió para solucionar cada una de las instancias. En comparación a los resultados obtenidos por GA, los tiempos de ejecución obtenidos por el algoritmo GRG aumentan cuando el tamaño de la instancia crece. Por lo tanto, la Figura 5.73 indica un crecimiento exponencial a medida que se agregan más variables al problema. Esta tendencia no lineal del esfuerzo computacional es típico cuando algoritmos clásicos “exactos” son implementados para solucionar problemas NP- Difíciles tal como lo es el problema de optimización del diseño de campos eólicos.



Figura 5. 73 Tiempo de ejecución que el algoritmo GRG invirtió para solucionar cada instancia

A continuación se presentan esquemáticamente los resultados presentados en la Tabla 5.11. Las figuras que esquemáticamente muestran las soluciones de distribución de aerogeneradores obtenidos mediante el Algoritmo Genético corresponden a la primera réplica.

La Figura 5.74 muestra la solución de distribución de aerogeneradores encontrada tanto por el algoritmo GRG y el Algoritmo Genético. Ambos algoritmos encontraron la solución óptima global para tal instancia. Dicha solución corresponde a la instancia de 3*4, es decir 12 posibles localizaciones y 8 aerogeneradores a instalar. Los aerogeneradores instalados en el centro de las cuadrículas se representan a través de puntos rellenos en color negro. La cifra posicionada por encima de los puntos rellenos de color negro representa la cantidad de energía (kW) producida por dicha turbina instalada en esa ubicación. Asimismo, en dicha figura es posible apreciar al igual que para todos los escenarios un viento incidente con dirección Norte-Sur con una velocidad de 12.8 m/s. Prácticamente los dos algoritmos encontraron la misma solución de distribución y por lo tanto de energía que fue de 4992.88 kW con una eficiencia del 99.20%. El tiempo computacional que invirtió el algoritmo GRG para encontrar esta solución fue de 48.656 segundos mientras que el GA invirtió 22.125 segundos. Cabe destacar que esta instancia se tomó como caso de prueba para iniciar este análisis de comparación entre algoritmos.

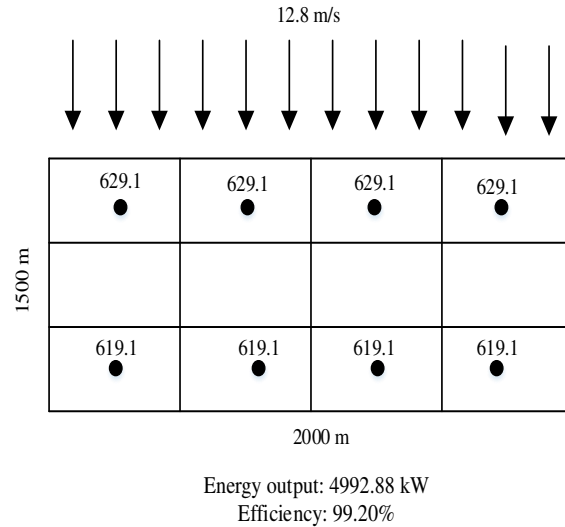


Figura 5. 74 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 3*4

La Figura 5.75 muestra la solución de distribución de aerogeneradores encontrada tanto por el algoritmo GRG y el Algoritmo Genético. Dicha solución corresponde a la instancia de 4*4, es decir 16 posibles localizaciones y 8 aerogeneradores a instalar. Asimismo, en la figura se puede apreciar la cantidad de energía total generada con esa distribución de aerogeneradores. El algoritmo GRG invirtió 164.328 segundos mientras que el Algoritmo Genético invirtió 36.578 segundos.




Figura 5. 75 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 4*4

La Figura 5.76 muestra la solución de distribución de aerogeneradores encontrada tanto por el algoritmo GRG y el Algoritmo Genético. Dicha solución corresponde a la instancia de 5*5, es decir 25 posibles localizaciones y 15 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa distribución de aerogeneradores. Para encontrar dicha solución, el algoritmo GRG invirtió 443.062 segundos mientras que el Algoritmo Genético invirtió 45.25 segundos.

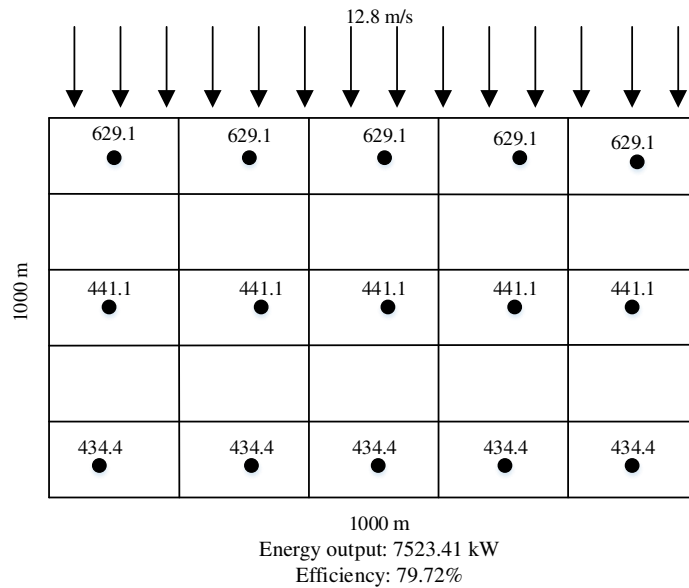


Figura 5. 76 Solución de distribución encontrada tanto por el algoritmo GRG y el Algoritmo Genético para la instancia 5*5

La Figura 5.77 muestra la solución de distribución de aerogeneradores encontrada por el algoritmo GRG para la instancia 6*6, en la cual se contemplaron 36 posibles localizaciones y 12 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa distribución de aerogeneradores. Para encontrar dicha solución, el algoritmo GRG invirtió 2780.75 segundos.




Figura 5. 77 Solución de distribución encontrada por el algoritmo GRG para la instancia 6*6

La Figura 5.78 muestra la solución de distribución de aerogeneradores encontrada por el Algoritmo Genético para la instancia 6*6, en la cual se contemplaron 30 posibles localizaciones y 12 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa solución de distribución de aerogeneradores. Para encontrar dicha solución, el Algoritmo Genético invirtió 36.219 segundos.




Figura 5. 78 Solución de distribución encontrada por el Algoritmo Genético para la instancia 6*6

La Figura 5.79 muestra la solución de distribución de aerogeneradores encontrada por el algoritmo GRG para la instancia 6*10, en la cual se contemplaron 60 posibles localizaciones y 20 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa solución de distribución de aerogeneradores. Para encontrar dicha solución, el algoritmo GRG invirtió 8910.54 segundos.




Figura 5. 79 Solución de distribución encontrada por el algoritmo GRG para la instancia 6*10

La Figura 5.80 muestra la solución de distribución de aerogeneradores encontrada por el Algoritmo Genético para la instancia 6*10, en la cual se contemplaron 30 posibles localizaciones y 12 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con dicha solución de distribución de aerogeneradores. Para encontrar dicha solución, el Algoritmo Genético invirtió 33.875 segundos.




Figura 5. 80 Solución de distribución encontrada por el Algoritmo Genético para la instancia 6*10

La Figura 5.81 muestra la solución de distribución de aerogeneradores encontrada por el algoritmo GRG para la instancia 7*7, en la cual se contemplaron 49 posibles localizaciones y 21 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa solución de distribución de aerogeneradores. Para encontrar dicha solución, el algoritmo GRG invirtió 18065.11 segundos.

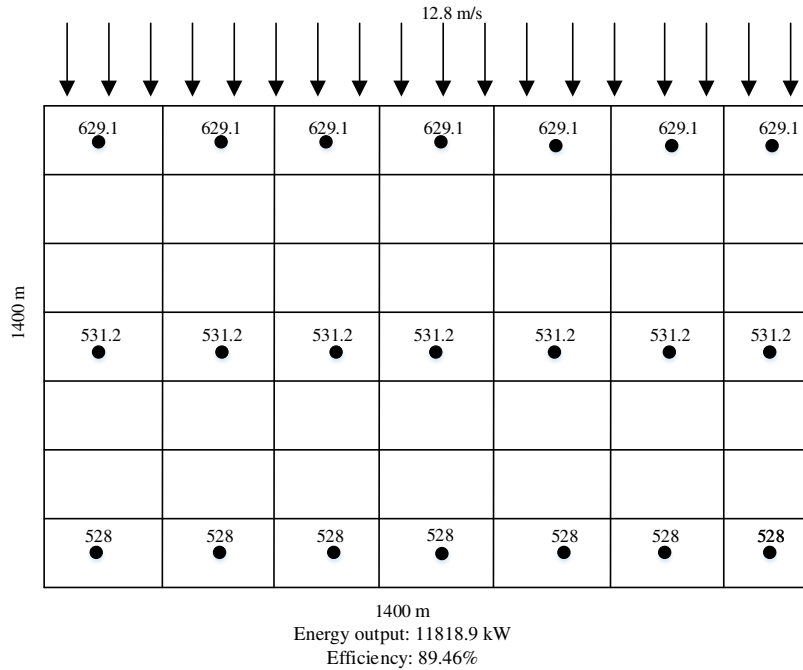


Figura 5. 81 Solución de distribución encontrada por el algoritmo GRG para la instancia 7*7

La Figura 5.82 muestra la solución de distribución de aerogeneradores encontrada por el Algoritmo Genético para la instancia 7*7, en la cual se contemplaron 49 posibles localizaciones y 21 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con dicha solución de distribución de aerogeneradores. Para encontrar dicha solución, el Algoritmo Genético invirtió 34.93 segundos.




Figura 5. 82 Solución de distribución encontrada por el Algoritmo Genético para la instancia 7*7

La Figura 5.83 muestra la solución de distribución de aerogeneradores encontrada por el algoritmo GRG para la instancia 7*10, en la cual se contemplaron 70 posibles localizaciones y 30 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con esa solución de distribución de aerogeneradores. Para encontrar dicha solución, el algoritmo GRG invirtió 60268.62 segundos.




Figura 5. 83 Solución de distribución encontrada por el algoritmo GRG para la instancia 7*10

La Figura 5.84 muestra la solución de distribución de aerogeneradores encontrada por el Algoritmo Genético para la instancia 7*10, en la cual se contemplaron 70 posibles localizaciones y 30 aerogeneradores a instalar. Asimismo, en dicha figura es posible apreciar la cantidad de energía total generada con dicha solución de distribución de aerogeneradores. Para encontrar dicha solución, el Algoritmo Genético invirtió 44.609 segundos.




Figura 5. 84 Solución de distribución encontrada por el Algoritmo Genético para la instancia 7*10

5.2 Conclusiones

En este trabajo de tesis, se explicó de forma general acerca del incremento de participación que la energía eólica ha ganado en los últimos años a nivel mundial, así como los principales factores que afectan el aprovechamiento óptimo de la cantidad de energía que se instala en un campo eólico, como lo son los efectos estela. Esta investigación se realizó con el objetivo de atacar el problema de optimización en campos eólicos, el cual se ha vuelto un tema de suma importancia y relevancia científica. La relevancia de este problema dentro de la comunidad científica recae en la dificultad para solucionar este problema en la práctica, ya que resulta sumamente complejo y costoso distribuir físicamente un conjunto de aerogeneradores en múltiples ocasiones en un campo eólico. Los diseñadores de campos eólicos muchas veces recurren a una distribución poco eficiente ya que no consideran los déficits de energía ocasionados por los efectos estela, dando como resultado la incapacidad de alcanzar el principal objetivo, el cual es producir la máxima cantidad de energía posible mediante el aprovechamiento del recurso del viento a partir de un determinado número de aerogeneradores y dimensiones de terreno disponibles. Es evidente que la producción de energía puede incrementarse significativamente si se reducen los fenómenos de efectos estela

entre los aerogeneradores tanto como sea posible, esto es posible solo si se diseña una distribución adecuada de aerogeneradores en un campo eólico. Por tal motivo, se propuso la utilización de un Algoritmo Genético aunado a un Diseño de Experimentos para que en conjunto brindaran soluciones de buena calidad en tiempos de cómputo razonables a distintos escenarios de campos eólicos que en esta investigación se resuelven. En el algoritmo también se consideró el modelo de Jensen, el cual modela los efectos estela y calcula las pérdidas de energía ocasionadas por dichos fenómenos cuando dos o más turbinas se encuentran localizadas a una distancia alemana y en dirección del viento incidente.

De acuerdo al Diseño de Experimentos realizado y a los resultados de los casos que se resuelven en este artículo se demostró que el algoritmo fue capaz de encontrar soluciones de alta calidad invirtiendo poco esfuerzo computacional, es decir el algoritmo se hizo robusto, lo cual impacta en dos aspectos importantes: la primera es que brinda muy buenas soluciones y la segunda es que el recurso energético que requiere la computadora para encontrar soluciones de alta calidad es relativamente bajo. Asimismo, los resultados presentados en esta investigación representan soluciones superiores en comparación a las soluciones reportadas por Gatscha (2016). La misma situación se presentó con el tiempo computacional. El algoritmo fue capaz de encontrar mejores soluciones debido a que primero se realizó un diseño de experimentos utilizando el escenario del Caso 1 con la finalidad de identificar aquellos valores de parámetros que brindaban la mayor cantidad de energía posible del campo eólico. Una vez que se obtuvieron estos valores de parámetros se decide utilizarlos para encontrar el diseño de otra instancia con 100 posibles localizaciones y 30 aerogeneradores, como fueron las variantes del Caso 2. Al utilizar dichos valores en las variantes del Caso 2 se concluyó que efectivamente el algoritmo encontraba soluciones de muy alta calidad invirtiendo poco tiempo de CPU. Los valores de los parámetros que se recomiendan para optimizar instancias de campos eólicos de tamaño considerable se presentan en la Tabla 5.13. Cabe indicar que la cantidad de iteraciones a la que se recomienda ejecutar el algoritmo es 100, sin embargo podría incrementarse si el usuario dispone de suficientes recursos y medios computacionales para hacerlo o si desea encontrar una mejor solución. A pesar de que el incremento del número de iteraciones no garantiza encontrar una mejor solución, la probabilidad de encontrarla se eleva.

Tabla 5. 13 Valores recomendados para los parámetros claves del Algoritmo Genético en R

Parámetro	Método de cruzamiento	Método de selección	Elitismo	Tasa de mutación	Número de iteraciones
Valor	RAN	FIX	TRUE	0.006	100

Para hacer una interpretación más real de la capacidad de suministro que representa la energía eléctrica producida en un campo eólico, se muestra la Tabla 5.14. En dicha tabla se realiza un análisis de abastecimiento de acuerdo a la solución energética encontrada en el Caso 1 y las variantes del Caso 2 de la presente investigación. Este análisis se basa de acuerdo al dato proporcionado por la Agencia Internacional de la Energía (AIE, 2018). La AIE declara que en el año 2014 el consumo promedio de energía eléctrica por persona en México fue de 2090.17 kWh.

Tabla 5. 14 Análisis de abastecimiento de energía eléctrica en México de acuerdo a las soluciones de los casos 1 y 2l

Caso	Solución energética en kWh	Número de personas beneficiadas en México
Caso 1	17307.26	8.28
Caso 2(a)	76325.98	36.51
Caso 2(b)	76954.07	36.81
Caso 2(c)	21597.06	10.33

De la misma manera, se realiza un análisis comparativo monetario entre las soluciones encontradas en esta tesis para las variantes del Caso 2 y las reportadas en la literatura. Dicho análisis se presenta en la Tabla 5.15. Este análisis resulta interesante para los productores de energía eólica, debido a que la rentabilidad de este tipo de proyectos resulta sumamente importante. Para el análisis se considera la tarifa que Comisión Federal de Electricidad (CFE)

aplica al servicio eléctrico doméstico básico por cada kWh consumido en México en el mes de noviembre del año 2018. La tarifa correspondiente de acuerdo a CFE (2018) es de 0.793 MXN/kWh. Por lo tanto, de acuerdo al análisis, las soluciones reportadas en esta investigación resultan más llamativas para los productores de energía eléctrica ya que brindan mayores utilidades.

Tabla 5. 15 Análisis monetario

Caso	Solución energética reportada en esta tesis (kWh)	Solución energética reportada en la literatura (kWh)	Utilidad que ofrece la solución de esta tesis (MXN/kWh)	Utilidad que ofrece la solución de la literatura (MXN/kWh)	Diferencia de utilidad (MXN/kWh)
Caso 2(a)	76325.98	75605.96	60526.50	59955.52	570.98
Caso 2(b)	76954.07	76516.77	61024.57	60677.79	346.78
Caso 2(c)	21597.06	21585.1	17126.46	17116.98	9.48

Las conclusiones correspondientes al Caso 3 se atribuyen al análisis comparativo de rendimiento de campos eólicos de acuerdo al número de aerogeneradores instalados. El análisis arrojó que a mayor número de turbinas instaladas, menor es la eficiencia del campo eólico y por lo tanto un mayor déficit de energía provocado por los efectos estela. Del análisis de regresión efectuado entre la energía y el número de turbinas, se concluye que la relación entre estas variables corresponde a un comportamiento lineal positivo. Del análisis de regresión entre el déficit total de energía de un campo eólico y el número de aerogeneradores, se concluye que la relación entre estas variables corresponde a un comportamiento polinómico.

Asimismo, a partir del escenario del Caso 3 se realizó un análisis de distribución de aerogeneradores de acuerdo a la dirección del viento incidente. En base a este análisis se

concluye que la energía total producida en un campo eólico no depende de la dirección del viento incidente. De la misma manera se concluye que las pérdidas de energía que un campo eólico podría experimentar debido a los efectos estela son independientes a la dirección del viento incidente. Por último, del Caso 3 también se concluye que un campo eólico produce mayor energía cuando se tiene un viento incidente con dirección a 45° , esto es porque las distancias entre las posibles localizaciones de aerogeneradores son mayores (distancia euclidiana) además del hecho de que en esta dirección el radio del efecto estela se reduce, provocando que las turbinas corriente arriba (las primeras que tienen interacción con el viento incidente) afectan una menor cantidad de turbinas corriente abajo.

Adicionalmente, en este trabajo de investigación se realizó una comparación de soluciones entre un método numérico (GRG non-linear) y el método metaheurístico descrito en este trabajo (Algoritmos Genéticos). Para la comparación se involucró la resolución de distintos escenarios concluyendo que el método metaheurístico brinda una solución de alta calidad en tiempos de cómputo razonables al problema de optimización del diseño de campos eólicos en comparación a un método numérico. El método numérico se configuró de tal manera que encontrara la solución óptima global para cada uno de los escenarios, invirtiendo una cantidad considerable de recurso computacional (tiempo de ejecución). El método metaheurístico evolutivo encontró para algunos escenarios (sobre todo los pequeños) la misma solución (óptima) que el método GRG-non linear pero en un menor tiempo. Para los escenarios de tamaño considerable, el método metaheurístico, no encontró la solución óptima global si no que brindó una solución aproximada invirtiendo poco esfuerzo computacional.

Cabe destacar que el objetivo principal de esta investigación es promover la sustentabilidad ambiental mediante el aprovechamiento óptimo de los recursos renovables como lo es el recurso del viento, el cual se ha convertido en uno de los recursos más prometedores para sustituir en el futuro a los combustibles fósiles para producir energía eléctrica. El consumo de energía que se produce a través de energías renovables como la energía eólica implica una reducción considerable del uso de combustibles fósiles, los cuales son sumamente contaminantes e insostenibles.

Por último, el código del algoritmo en R del paquete “windfarmGA” utilizado en esta investigación fue desarrollado por Gatscha (2016) y se encuentra disponible para descarga en CRAN (2018). Por lo tanto, los investigadores o usuarios en general pueden dirigirse al repositorio para descargar el paquete y optimizar campos eólicos reales. Dicho paquete puede servir como una herramienta de refinamiento para mejorar escenarios iniciales de distribución de campos eólicos o campos eólicos diseñados a partir de principios y reglas de distribución recomendadas por diseñadores expertos u otros métodos empíricos de diseño. Asimismo, puede servir como una herramienta de optimización para encontrar la mejor distribución de un cierto número de aerogeneradores a instalar en un campo eólico con forma irregular.

Bibliografía

- Ackoff, R., & Sasieni, M. (1968). *Fundamentals of operations research*. New York: John Wiley and Sons.
- AIE. (2018). *Consumo de energía eléctrica (kWh per cápita)*. Obtenido de <https://datos.bancomundial.org/indicador/EG.USE.ELEC.KH.PC>
- Andaluz, A. M. (7 de Mayo de 2018). *Universidad Carlos III de Madrid*. Obtenido de Universidad Carlos III de Madrid: www.it.uc3m.es/jvillena/irc/practicas/estudios/aeag.pdf
- Asimow, M. (1962). *Introduction to Design*. USA: Prentice-Hall.
- Balcells, J. (2011). *Eficiencia en el uso de la energía eólica*. Barcelona, España: Marcombo, S.A.
- Barthelmie, R., Hansen, K., Frandsen, S., Rathmann, O., Schepers, J., Schlez, W., . . . Chaviaropoulos, P. (2009). Modelling and measuring flow and wind turbine wakes in large wind farms offshore. *Wind Energy*, 12, 431-444. doi:10.1002/we.348
- Bilbao, M., & Alba, E. (2011). Algoritmos Evolutivos Aplicados al Diseño Inteligente de Parques Eólicos. *XVII CONGRESO ARGENTINO DE CIENCIAS DE LA COMPUTACIÓN* (págs. 11-20). La Plata: CACIC.
- CFE. (2018). *Comisión Federal de Electricidad*. Obtenido de <https://www.cfe.mx/tarifas/Pages/Tarifas.aspx>
- Chen, Y., Li, H., Jin, K., & Song, Q. (2013). Wind farm optimization using genetic algorithm with different hub height wind turbines. *Energy Conversion and Management*, 70, 56-65.
- DuPont, B., & Cagan, J. (2016). A hybrid extended pattern search/genetic algorithm for multi-stage wind farm optimization. *Optimization and Engineering*, 17, 77-103. doi:10.1007/s11081-016-9308-3
- Emami, A., & Noghreh, P. (2010). New approach on optimization in placement of wind turbines within wind farm by genetic algorithms. *Renewable Energy*, 35, 1559-1564.

- Eppen, G. D., Gould, F. J., Schmidt, C. P., Moore, J. H., & Weatherford, L. R. (2000). *Investigación de operaciones en la ciencia administrativa*. México: Prentice Hall Hispanoamericana, S.A.
- Eroğlu, Y., & Seçkiner, S. U. (2012). Design of wind farm layout using ant colony algorithm. *Renewable Energy*, *44*, 53-62.
- Eroğlu, Y., & Seçkiner, S. U. (2013). Wind farm layout optimization using particle filtering approach. *Renewable Energy*, *58*, 95-107.
- Feng, J., & Shen Zhong, W. (2015). Solving the wind farm layout optimization problem using random search algorithm. *Renewable Energy*, *78*, 182-192.
- Fischetti, M., & Monaci, M. (2016). Proximity search heuristics for wind farm optimal layout. *Journal of Heuristics*, *22*, 459-474. doi: 10.1007/s10732-015-9283-4
- Gatscha, S. (2016). *Generic Optimization of a Wind Farm Layout using a Genetic Algorithm* (Master's thesis). University of Natural Resources and Life Science, Vienna, Austria.
- Gutiérrez Pulido, H., & De la Vara Salazar, R. (2008). *Análisis y diseño de experimentos*. México, D.F: McGraw-Hill/Interamericana Editores, S.A de C.V.
- Hillier, F. S., & Lieberman, G. J. (2010). *Introducción a la Investigación de Operaciones* (Novena ed.). México, D.F.: McGraw-Hill/Interamericana Editores, S.A de C.V.
- Kusiak, A., & Zong, Z. (2009). Design of wind farm layout for maximum wind energy capture. *Renewable Energy*, *35*, 685-694. doi:10.1016/j.renene.2009.08.019
- Lackner, M. A., & Elkinton, C. N. (2007). An analytical framework for offshore wind farm layout optimization. *Wind Engineering*, 17-31.
- Montgomery, D. (2011). *Diseño y análisis de experimentos*. México, D.F: Editorial Limusa, S.A de C.V.
- Morales, L. R. (2004). *Diseño: estrategia y táctica*. México, D.F: Siglo XXI.
- Munari, B. (2008). *Diseño y comunicación visual*. Barcelona, España: Editorial Gustavo Gili.
- Muñoz, A. D., Pantrigo Fernández, J. J., & Gallego Carrillo, M. (2007). *Metaheurísticas*. Madrid, España: DYKINSON. S.L.
- Nieves, A. A. (2011). *Gestión del mantenimiento de instalaciones de energía eólica*. Málaga, España: Publicaciones Vértice, S.L.

- Nieves, A. A. (2011). *Operaciones y puesta en servicio de instalaciones de energía eólica*. Málaga, España: Editorial Vértice.
- Pérez, B., Mínguez, R., & Guanche, R. (2013). Offshore wind farm layout optimization using mathematical programming techniques. *Renewable Energy*, 53, 389-399.
- Prawda, J. (1982). *Métodos y modelos de investigación de operaciones*. México, D.F: EDITORIAL LIMUSA S.A.
- Samorani, M. (2013). The Wind Farm Layout Optimization Problem. En P. Pardalos, S. Rebennack, M. Pereira, N. Iliadis, & V. Pappu, *Handbook of Wind Power Systems. Energy Systems*. (págs. 21-38). Berlin: Springer.
- Scott, R. G. (1951). *Fundamentos del diseño*. Buenos Aires, Argentina: EDITORIAL VICTOR LERU S.A.
- Shakoor, R., Hassan, M. Y., Raheem, A., & Wu, Y.-K. (2016). Wake effect modeling: A review of wind farm layout optimization using Jensen's model. *Renewable and Sustainable Energy Reviews*, 58, 1048-1059.
- Taha, H. A. (2012). *Investigación de operaciones* (Novena ed.). Cd. México: Pearson Educación de México, S.A de C.V.
- The Comprehensive R Archive Network (CRAN)*. (2018). Obtenido de <https://cran.r-project.org/>
- Walker, J. (2009). *Fundamentos de Física, Vol. 1*. México, D.F: Grupo Editorial Patria S.A de C.V.
- Wan, C., Wang, J., Yang, G., Gu, H., & Zhang, X. (2012). Wind farm micro-siting by Gaussian particle swarm optimization with local search strategy. *Renewable Energy*, 48, 276-286.

ANEXO A: Código de programación en R para el Caso 1 (Gatscha, 2016)

```

1. ## Case of study 1
2. library(sp)
3. t <- proc.time()
4. Polygon1 <- Polygon(rbind(c(0, 0), c(0, 719.9),c(630, 719.9),
c(630, 0)))
5. Polygon1 <- Polygons(list(Polygon1), 1);
6. Polygon1 <- SpatialPolygons(list(Polygon1))
7. Projection <- "+proj=laea +lat_0=52 +lon_0=10 +x_0=4321000
+y_0=3210000 +ellps=GRS80 +towgs84=0,0,0,0,0,0,0 +units=m
+no_defs"
8. proj4string(Polygon1) <- CRS(Projection)
9. plot(Polygon1,axes=TRUE)
10. ## Create a Grid
11. GridFilter(Polygon1, resol= 90 ,prop=1,TRUE)
12. ## Create a uniform and unidirectional wind data.frame and
plot the
13. ## resulting wind rose
14. data.in <- as.data.frame(cbind(ws=12,wd=0))
15. windrosePlot <- plotWindrose(data = data.in, spd =
data.in$ws,
16. dir = data.in$wd, dirres=10, spdmax=20)
17. ## Runs an optimization run for 100 iterations (iteration)
with the given shapefile (Polygon1), the wind data.frame
(data.in),
18. ## 12 turbines (n) with rotor radii of 30m (Rotor) and a
grid spacing
19. ## factor of 3 (fcrR) and other required inputs
20.
21. result <- genAlgo(Polygon1 = Polygon1, GridMethod = "r",
n=12, Rotor=30,fcrR=3,iteration=100,
22. vdirspe = data.in,crossPart1
="EQU",selstate="FIX",mutr=0.01,
23. Proportionality = 1, SurfaceRoughness = 0.14,
topograp = FALSE,
24. elitism = TRUE, nelit = 6, trimForce = FALSE,
25. referenceHeight = 60, RotorHeight = 60,
Parallel = TRUE, numCluster = 2)
26. PlotWindfarmGA(result, GridMethod = "r", Polygon1, best =
1, plotEn = 1)
27. leafPlot(result, Polygon1, which = 1, orderitems = TRUE)
28. proc.time()-t

```

ANEXO B: Código de programación en R para el Caso 2 (Gatscha, 2016)

```

1. ## Create a random rectangular shapefile (Case of study 2)
2. library(sp)
3. t <- proc.time()
4. Polygon1 <- Polygon(rbind(c(0, 0), c(0, 2000), c(2000, 2000),
  c(2000, 0)))
5. Polygon1 <- Polygons(list(Polygon1), 1);
6. Polygon1 <- SpatialPolygons(list(Polygon1))
7. Projection <- "+proj=laea +lat_0=52 +lon_0=10 +x_0=4321000
  +y_0=3210000 +ellps=GRS80 +towgs84=0,0,0,0,0,0,0 +units=m
  +no_defs"
8. proj4string(Polygon1) <- CRS(Projection)
9. plot(Polygon1, axes=TRUE)
10.     ## Create a Grid
11.     GridFilter(Polygon1, resol= 200 ,prop=0.99,TRUE)
12.     ## Create a uniform and unidirectional wind data.frame and
  plot the
13.     ## resulting wind rose
14.     data.in <- as.data.frame(cbind(ws=12,wd=0))
15.     windrosePlot <- plotWindrose(data = data.in, spd =
  data.in$ws,
16.                                   dir = data.in$wd, dirres=10,
  spdmax=20)
17.     ## Runs an optimization run for 100 iterations (iteration)
  with the
18.     ## given shapefile (Polygon1), the wind data.frame
  (data.in),
19.     ## 30 turbines (n) with rotor radii of 20m (Rotor) and a
  grid spacing
20.     ## factor of 10 (fcrR) and other required inputs
21.     result <- genAlgo(Polygon1 = Polygon1, GridMethod = "r",
  n=30, Rotor=20,fcrR=10,iteration=100,
22.                       vdirspe = data.in,crossPart1 =
  "RAN",selstate="FIX",mutr=0.006,
23.                       Proportionality = 0.99, SurfaceRoughness
  = 0.3, topograp = FALSE,
24.                       elitism=TRUE, nelit = 7, trimForce =
  TRUE,
25.                       referenceHeight = 60,RotorHeight =
  60,Parallel = TRUE, numCluster = 2)
26.     PlotWindfarmGA(result, GridMethod = "r", Polygon1, best =
  1, plotEn = 1)
27.     leafPlot(result, Polygon1, which = 1, orderitems = TRUE)
28.     proc.time()-t

```

ANEXO C: Código de programación en R para el Caso 3 (Gatscha, 2016)

```

1. ## Create a random rectangular shapefile (Caso 3 variando la
   dirección del viento y el número de turbinas)
2. library(sp)
3. t <- proc.time()
4. Polygon1 <- Polygon(rbind(c(0, 0), c(0, 3000),c(3000, 3000),
   c(3000, 0)))
5. Polygon1 <- Polygons(list(Polygon1),1);
6. Polygon1 <- SpatialPolygons(list(Polygon1))
7. Projection <- "+proj=laea +lat_0=52 +lon_0=10 +x_0=4321000
   +y_0=3210000 +ellps=GRS80 +towgs84=0,0,0,0,0,0,0 +units=m
   +no_defs"
8. proj4string(Polygon1) <- CRS(Projection)
9. plot(Polygon1,axes=TRUE)
10.    ## Create a Grid
11.    GridFilter(Polygon1, resol= 300 ,prop=0.99,TRUE)
12.    ## Create a uniform and unidirectional wind data.frame and
   plot the
13.    ## resulting wind rose
14.    data.in <- as.data.frame(cbind(ws=12,wd=45))
15.    windrosePlot <- plotWindrose(data = data.in, spd =
   data.in$ws,
16.                                dir = data.in$wd, dirres=10,
   spdmax=20)
17.    ## Runs an optimization run for 100 iterations (iteration)
   with the
18.    ## given shapefile (Polygon1), the wind data.frame
   (data.in),
19.    ## 35 turbines (n) with rotor radii of 30m (Rotor) and a
   grid spacing
20.    ## factor of 10 (fcrR) and other required inputs
21.    result <- genAlgo(Polygon1 = Polygon1, GridMethod = "r",
   n=35, Rotor=30,fcrR=10,iteration=100,
22.                    vdirspe = data.in,crossPart1 =
   "RAN",selstate="FIX",mutr=0.006,
23.                    Proportionality = 0.99, SurfaceRoughness
   = 0.0002, topograp = FALSE,
24.                    elitism=TRUE, nelit = 7, trimForce =
   TRUE,
25.                    referenceHeight = 60,RotorHeight =
   60,Parallel = TRUE, numCluster = 2)
26.    PlotWindfarmGA(result, GridMethod = "r", Polygon1, best =
   1, plotEn = 1)
27.    leafPlot(result, Polygon1, which = 1, orderitems = TRUE)
28.    proc.time()-t

```

ANEXO D: Publicación de artículo derivado de tesis en la revista Engineering and Technology

Engineering and Technology Journal e-ISSN: 2456-3358

Volume 04 Issue 05 May- 2019, Page No.-597-612

DOI:10.31142/etj/v4i5.03, I.F. - 4.449

© 2019, ETJ



Wind Farm Layout Optimization Using Genetic Algorithms and Design of Experiments

Abelardo Buentello-Duque¹, Salvador Hernández-González², José A. Jiménez-García²,
Vicente Figueroa-Fernández³, Moisés Tapia-Esquivias⁴

^{1,2,3,4,5}Tecnológico Nacional de México en Celaya, Department of Industrial Engineering, Av. Garcia Cubes 1200, Esquina Ignacio Borunda, Celaya, Gto. México. Tel. 01 (461)61 17575

Abstract: Wind power has become the renewable energy with more participation in countries looking for environmental sustainability. Wind power is transformed into electric power by means of wind turbines, which are generally grouped in wind farms to exploit the relative benefits to economies of scale. The efficient design of a wind farm requires a set of wind turbines to be distributed to produce the maximum amount of installed energy. One of the typical factors to be considered for the optimal design of a wind farm is the interaction between the fields of operation of the wind turbines or the wake effect, wake effect provokes a considerable loss of power, so it is important when designing a wind farm to consider said wake effects in such a way as to maximize the expected energy production. The wind farm layout optimization problem is considered an NP-hard optimization problem, as there is no algorithm that can solve it in polynomial computation time. This research proposes the implementation of an evolutionary metaheuristic to find the optimal allocation of turbines in wind farms, considering the wake effect. In order to find those parameters of the genetic algorithm that provide high quality solutions in reasonable computation time, a factorial experimental design 2^3 was used. The results of the solved instances demonstrated that the metaheuristic method and the design of experiments technique provide different configurations that improve up to 1% in both utility and power generation than the previous configurations proposed in the literature in reasonable computing times.

Keywords: wind farm, wake effect, artificial intelligence, combinatorial optimization, genetic algorithms, design of experiments, renewable energy, metaheuristic.

I. INTRODUCTION

Wind power is considered to be the fastest growing source of renewable energy since worldwide production grew significantly between 2005 and 2008, reaching 121.2 GW of total installed capacity. Which has made this green energy an extremely interesting topic in the last few years. Environmental sustainability demands a considerable reduction in the use of fossil fuels, which are extremely contaminating and unsustainable, so ambitious plans have been proposed for the production of green energy, including wind power [1]. Wind power is transformed into electric power by means of wind turbines, which are generally grouped in wind farms to exploit the relative benefits to economies of scale, such as lower costs of installation and maintenance [2]. A wind farm's design is an important component in guaranteeing the profitability of a wind farm project. A bad design or an unsuitable wind turbine layout in wind farms might result in a lower production of wind power compared to expected production, higher maintenance costs; among other unsatisfactory aspects [3].

The wind farm layout optimization problem consists of finding an optimal allocation of wind turbines on a particular site that maximizes energy production. In practice

this is an extremely difficult problem, because of the size of the instances in real applications, having to take into account a huge number of complex conditions, together with the presence of nonlinear factors [1], which amount to a considerable financial investment owing to the high consumption of necessary resources (time, labor, equipment, etc) required for the optimal design of a wind farm. The wind farm layout optimization problem is considered to be an NP-hard optimization problem, as there is no algorithm that can solve it in polynomial computation time. Because of the computation resource needed to solve this optimization problem, exact algorithms would an unreasonable amount of computation time [4]. Therefore, in view of this complexity, rigorous optimization approaches such as: branch and bound, dynamic programming, linear programming, etc can be used in smaller-scale instances [5]. Consequently, a metaheuristic approach needs to be used, except in situations where the wind farms are very small [6]. There are a series of optimization techniques and methods that have been successfully used in the wind farm layout optimization problem, among which genetic algorithms [7-8] particularly stand out.

ANEXO E: Publicación de artículo derivado de tesis en la revista *Pistas Educativas*

Pistas Educativas, No. 132, junio 2019, México, Tecnológico Nacional de México en Celaya

RESOLVIENDO EL PROBLEMA DE OPTIMIZACIÓN DEL DISEÑO DE PARQUES EÓLICOS EMPLEANDO ALGORITMOS GENÉTICOS

*SOLVING THE WIND FARM LAYOUT OPTIMIZATION PROBLEM
USING GENETIC ALGORITHMS*

Abelardo Buentello Duque

Tecnológico Nacional de México en Celaya, México
M1703073@itcelaya.edu.mx

Salvador Hernández González

Tecnológico Nacional de México en Celaya, México
salvador.hernandez@itcelaya.edu.mx

José Alfredo Jiménez García

Tecnológico Nacional de México en Celaya, México
alfredo.jimenez@itcelaya.edu.mx

Resumen

La construcción de parques eólicos está destinada a incrementarse en los países que buscan la sustentabilidad ambiental. Una etapa importante en la construcción de parques eólicos es resolver el problema de optimización del diseño del parque, el cual consiste en distribuir un conjunto de aerogeneradores de tal manera que las pérdidas de energía ocasionadas por los efectos estela se minimicen y la producción de energía esperada se maximice. El efecto estela es un fenómeno que debe ser tomado en cuenta para obtener la mejor configuración de un campo eólico. Este problema es considerado por la comunidad científica como un problema de optimización NP-Duro, causando suma atención y relevancia. En esta investigación se implementa una metaheurística evolutiva, específicamente algoritmos genéticos para encontrar la ubicación óptima de aerogeneradores, considerando el efecto estela. Los resultados demuestran que el método metaheurístico provee una solución de configuración de alta calidad en un tiempo computacional razonable.

Palabras Clave: Algoritmos Genéticos, Aerogeneradores, Campos Eólicos, Efecto Estela, Optimización combinatoria.