



CARTA DE AUTORIZACIÓN

CÓDIGO

AP-BIB-FO-06

VERSIÓN

1

VIGENCIA

2014

PÁGINA

1 de 2

Neiva, 06 de noviembre del 2019

Señores

CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN

UNIVERSIDAD SURCOLOMBIANA

Ciudad

El (Los) suscrito(s):

__Juan Sebastian Mejía Rincón_____, con C.C. No. __1.075.294.541_____,
_____, con C.C. No. _____,
_____, con C.C. No. _____,
_____, con C.C. No. _____,

Autor(es) de la tesis y/o trabajo de grado o _proyecto de grado_____

titulado _Modelo de predicción de radiación solar usando técnicas inteligentes_____

presentado y aprobado en el año __2019__ como requisito para optar al título de

__Ingeniero electrónico_____;

Autorizo (amos) al CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN de la Universidad Surcolombiana para que, con fines académicos, muestre al país y el exterior la producción intelectual de la Universidad Surcolombiana, a través de la visibilidad de su contenido de la siguiente manera:

- Los usuarios puedan consultar el contenido de este trabajo de grado en los sitios web que administra la Universidad, en bases de datos, repositorio digital, catálogos y en otros sitios web, redes y sistemas de información nacionales e internacionales "open access" y en las redes de información con las cuales tenga convenio la Institución.
- Permita la consulta, la reproducción y préstamo a los usuarios interesados en el contenido de este trabajo, para todos los usos que tengan finalidad académica, ya sea en formato Cd-Rom o digital desde internet, intranet, etc., y en general para cualquier formato conocido o por conocer, dentro de los términos establecidos en la Ley 23 de 1982, Ley 44 de 1993, Decisión Andina 351 de 1993, Decreto 460 de 1995 y demás normas generales sobre la materia.
- Continúo conservando los correspondientes derechos sin modificación o restricción alguna; puesto que, de acuerdo con la legislación colombiana aplicable, el presente es un acuerdo jurídico que en ningún caso conlleva la enajenación del derecho de autor y sus conexos.

Vigilada Mineducación



CARTA DE AUTORIZACIÓN

CÓDIGO

AP-BIB-FO-06

VERSIÓN

1

VIGENCIA

2014

PÁGINA

2 de 2

De conformidad con lo establecido en el artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, “Los derechos morales sobre el trabajo son propiedad de los autores” , los cuales son irrenunciables, imprescriptibles, inembargables e inalienables.

EL AUTOR/ESTUDIANTE:

Firma: Juan S. Mejía R

EL AUTOR/ESTUDIANTE:

Firma: _____

EL AUTOR/ESTUDIANTE:

Firma: _____

EL AUTOR/ESTUDIANTE:

Firma: _____



TÍTULO COMPLETO DEL TRABAJO:

AUTOR O AUTORES:

Primero y Segundo Apellido	Primero y Segundo Nombre
MEJIA RINCON	JUAN SEBASTIAN

DIRECTOR Y CODIRECTOR TESIS:

Primero y Segundo Apellido	Primero y Segundo Nombre
MOSQUERA CERQUERA	VLADIMIR

ASESOR (ES):

Primero y Segundo Apellido	Primero y Segundo Nombre
----------------------------	--------------------------

PARA OPTAR AL TÍTULO DE: INGENIERO ELECTRÓNICO

FACULTAD: INGENIERIA

PROGRAMA O POSGRADO: INGENIERIA ELECTRÓNICA

CIUDAD: NEIVA

AÑO DE PRESENTACIÓN: 2019

NÚMERO DE PÁGINAS: 140

TIPO DE ILUSTRACIONES (Marcar con una X):

Diagramas Fotografías Grabaciones en discos Ilustraciones en general Grabados
Láminas Litografías Mapas Música impresa Planos Retratos Sin ilustraciones Tablas
o Cuadros



SOFTWARE requerido y/o especializado para la lectura del documento:

MATERIAL ANEXO: Datos meteorológicos utilizados en el desarrollo del modelo de predicción, Tabla de resultados y convenciones del modelo neuronal previo, Tabla de reglas y convenciones del modelo difuso previo, Tabla de reglas y convenciones del modelo difuso, Tabla de reglas y convenciones del modelo difuso.

PREMIO O DISTINCIÓN (*En caso de ser LAUREADAS o Meritoria*):

PALABRAS CLAVES EN ESPAÑOL E INGLÉS:

<u>Español</u>	<u>Inglés</u>	<u>Español</u>	<u>Inglés</u>
1. Radiación solar	Solar Radiation	6. Lógica Difusa	Fuzzy Logic
2. Variables meteorológicas	Meteorological variables	7. Inteligencia Artificial	Artificial Intelligence
3. Predicción	Prediction	8. _____	_____
4. Energía	Energy	9. _____	_____
5. Redes Neuronales Artificiales	Artificial Neural Networks		

RESUMEN DEL CONTENIDO: (Máximo 250 palabras)

Muchas de las actividades del ser humano están condicionadas a los cambios de las variables meteorológicas y sus efectos. La radiación solar es la mayor fuente de energía para los seres vivos, por eso se puede afirmar que la estimación de esta es bastante pertinente y más si se tiene en cuenta que su medición es complicada y costosa debido a que la energía solar no es planificable por el comportamiento estocástico de las condiciones climatológicas, además porque los equipos para su medición no se pueden adquirir fácilmente por precio y disponibilidad. Este trabajo presenta el desarrollo de un modelo de predicción de radiación solar usando técnicas basadas en Inteligencia Artificial: Redes Neuronales Artificiales (RNA) y Lógica Difusa, con el fin de alcanzar una mayor precisión de predicción de la radiación solar a la presentada por los modelos estadísticos y físicos comúnmente usados.



Empty box for the description of the thesis or degree work.

ABSTRACT: (Máximo 250 palabras)

Many human being activities are conditioned by the changes of the meteorological variables and their effects. Solar radiation is the greatest energy source for living beings, that is why it is possible to say that the estimation of this one is quite complicated and expensive because solar energy is not planned due to the stochastic behavior of weather conditions, furthermore because the equipment for its measurement are not easily acquired because of the price and availability. This project introduces the development of a solar radiation prediction model using techniques based on AI: Artificial Neural Networks (ANN) and Fuzzy Logic, in order to achieve greater prediction accuracy of solar radiation than those given by statistical and physical models commonly used.



APROBACION DE LA TESIS

Nombre Presidente Jurado:

Firma:

Nombre Jurado: Johan Julian Molina Mosquera

Firma:

Nombre Jurado: Julian Adolfo Ramirez Gutierrez

Firma:

**MODELO DE PREDICCIÓN DE RADIACIÓN SOLAR USANDO TÉCNICAS
INTELIGENTES**

PRESENTADO POR

JUAN SEBASTIÁN MEJÍA RINCÓN

TESIS DE GRADO PARA OPTAR AL TÍTULO DE INGENIERO ELECTRÓNICO

**UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA
2019**

**MODELO DE PREDICCIÓN DE RADIACIÓN SOLAR USANDO DE TÉCNICAS
INTELIGENTES**

PRESENTADO POR

JUAN SEBASTIÁN MEJÍA RINCÓN

TESIS DE GRADO PARA OPTAR AL TÍTULO DE INGENIERO ELECTRÓNICO

Director
Vladimir Mosquera Cerquera
Magister en Ingeniería Electrónica

UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA
2019

Nota de aceptación:

Firma del presidente del Jurado

Firma del Jurado

Firma del Jurado

Neiva, Septiembre 26 de 2019

AGRADECIMIENTOS

Quiero agradecer profundamente a mi madre María y mi tío Cesar por su apoyo incondicional y constante durante toda mi carrera universitaria y la elaboración de este proyecto de grado.

Agradezco a Dios por iluminarme siempre y permitirme cumplir con los objetivos propuestos.

También quiero expresar mi gratitud hacia el ingeniero Vladimir Mosquera quien fue el director de este proyecto y un guía permanente. Sin su ayuda, consejos, paciencia y tiempo no habría logrado avanzar en el cumplimiento de esta meta.

Igualmente, quiero agradecer a mis compañeros de estudio, con los cuales compartí muchas cosas. Siempre me brindaron su apoyo y conocimientos durante todos estos años.

Quiero hacer una mención especial a todos los ingenieros, maestros y doctores a los cuales molesté incontables veces para expresarles mis dudas y preguntas sobre el tema. Debido a la cantidad no puedo mencionarlos, pero agradezco infinitamente su ayuda y su tiempo.

Sin la ayuda y apoyo de las personas mencionadas anteriormente no habría sido posible la culminación de este trabajo de grado, que más que un proyecto es una meta personal. Las ideas y consejos brindados que, aunque tal vez sencillos y básicos para ustedes, fueron muy significativos y relevantes para mí.

DEDICATORIA

A mi madre y mi tío por ser los pilares en mi formación académica y personal, por su apoyo incondicional y por ser una motivación constante para cumplir las metas propuestas.

A mi maestro Vladimir Mosquera por su tiempo compartido, consejos y deseo de impulsar el desarrollo de mi formación profesional.

A mis amigos, que nos apoyamos mutuamente en nuestra formación profesional.

Por último, a los maestros, aquellos que me ayudaron en asesorías y dedicaron parte de su tiempo despejando las dudas presentadas en la elaboración de este proyecto.

Todo este trabajo ha sido posible gracias a ellos.

“El valor de un acto reside más en el esfuerzo para llevarlo a cabo que en el resultado”.
Albert Einstein.

TABLA DE CONTENIDO

	Página
Capítulo 1. Generalidades	13
1.1. Introducción	13
1.2.1. Objetivo General	14
1.2.2. Objetivos Específicos.....	14
1.3. Justificación y planteamiento del problema	14
Capítulo 2. Factores influyentes en la radiación solar.....	16
Capítulo 3. Modelos de predicción.	18
3.1. Adquisición de datos	18
3.2. Variables relevantes	21
3.3. Validación de resultados.....	35
3.4. Modelos propuestos inicialmente.....	37
3.4.1. Modelo neuronal previo	37
3.4.2. Modelo difuso	39
Capítulo 4. Modelo neuronal para predicción de radiación solar.....	46
4.1. Datos de entrada y salida para el modelo de predicción neuronal	49
4.2. Diseño estructural del modelo de predicción neuronal	49
4.3. Construcción y entrenamiento del modelo de predicción neuronal	51
4.4. Modelo neuronal simple	54
Capítulo 5. Modelo de inferencia difuso para predicción de radiación solar.....	55
5.1. Datos de entrada y salida.....	56
5.2. Funciones de membresía y universo de discurso.....	56
5.3. Reglas de inferencia	67
5.4. Modelo de inferencia difuso simple	67
Capítulo 6. Resultados, conclusiones y trabajos futuros.	68
6.1. Resultados obtenidos.....	68
6.1.1. Modelos neuronales	68
6.1.2. Modelos difusos	73

6.2. Conclusiones	76
6.3. Trabajos futuros.....	79
Referencias.....	80
ANEXOS	83

LISTA DE FIGURAS

	Página
Figura 1. Pantalla de inicio de WEKA.....	23
Figura 2. Gráficas de dispersión.....	35
Figura 3. Diagrama del modelo de predicción neuronal previo con cinco variables de entrada, dos capas ocultas de ochenta y veinte neuronas cada una, y una capa de salida. ..	38
Figura 4. Datos suavizados de radiación solar.....	39
Figura 5. Resultados modelo neuronal previo.	39
Figura 6. Diagrama del modelo Fuzzy.....	40
Figura 7. Funciones de membresía de horas de brillo solar.....	41
Figura 8. Funciones de membresía de nubosidad.	41
Figura 9. Funciones de membresía de temperatura máxima.....	42
Figura 10. Funciones de membresía de temperatura mínima.	42
Figura 11. Funciones de membresía de humedad relativa.....	43
Figura 12. Funciones de membresía de velocidad del viento.	43
Figura 13. Funciones de membresía de precipitación.....	44
Figura 14. Funciones de membresía de radiación solar.....	44
Figura 15. Resultados modelo Fuzzy.....	45
Figura 16. Perceptrón multicapa.	46
Figura 17. Estructura de las redes SOM.....	48
Figura 18. Diagrama de las redes neuronales feed-forward.....	48
Figura 19. Etapas de desarrollo del modelo neuronal de predicción de radiación solar.	49
Figura 20. Representación genérica del modelo de predicción neuronal.....	50
Figura 21. Estructura del modelo neuronal.....	53
Figura 22. Diagrama del procesamiento general del sistema difuso: Mamdani (a) y Sugeno (b).....	55
Figura 23. Representación genérica del modelo de predicción fuzzy.....	57
Figura 24. Distribución de datos de horas de brillo solar.	58
Figura 25. Distribución de datos de nubosidad.....	58

Figura 26. Distribución de datos de temperatura máxima.	59
Figura 27. Distribución de datos de temperatura mínima.	59
Figura 28. Distribución de datos de humedad relativa.....	60
Figura 29. Distribución de datos de velocidad del viento.....	60
Figura 30. Distribución de datos de precipitaciones.	61
Figura 31. Distribución de datos de radiación solar.....	61
Figura 32. Funciones de membresía de horas de brillo solar.....	63
Figura 33. Funciones de membresía de nubosidad.	63
Figura 34. Funciones de membresía de temperatura máxima.....	64
Figura 35. Funciones de membresía de temperatura mínima.	64
Figura 36. Funciones de membresía de humedad relativa.	65
Figura 37. Funciones de membresía de velocidad del viento.	65
Figura 38. Funciones de membresía de precipitación.....	66
Figura 39. Funciones de membresía de radiación solar.	66
Figura 40. Predicción de radiación solar obtenida por el modelo neuronal SOM y feed-forward con siete variables de entrada, 10 y 10 neuronas en las capas ocultas.	70
Figura 41. Predicción de radiación solar obtenida por el modelo neuronal SOM y feed-forward con cinco variables de entrada, 10 neuronas en la capa oculta.	72
Figura 42. Predicción de radiación solar obtenida por el modelo neuronal feed-forward con una variable de entrada, 20 y 10 neuronas en las capas ocultas.....	73
Figura 43. Predicción de radiación solar obtenida por el modelo fuzzy con siete variables de entrada.	74
Figura 44. Predicción de radiación solar obtenida por el modelo fuzzy con una variable de entrada.	75

LISTA DE TABLAS

	Página
Tabla 1. Estaciones Meteorológicas.....	18
Tabla 2. Coeficiente de Correlación de Pearson calculado en Matlab.....	21
Tabla 3. Evaluador de atributos CFsSubsetEval, método de búsqueda BestFirst y Cross-Validation de 10 folds.	24
Tabla 4. Evaluador de atributos ReliefFAttributeEval, método de búsqueda Ranker y Cross-Validation de 10 folds.	25
Tabla 5. Evaluador de atributos ReliefFAttributeEval, con filtro aplicado.	25
Tabla 6. Número de funciones de membresía por variable.....	62
Tabla 7. Resultados del modelo neuronal SOM y feed-forward con siete variables de entrada.	69
Tabla 8. Resultados del modelo neuronal SOM y feed-forward con cinco variables de entrada.	71
Tabla 9. Resultados del modelo neuronal feed-forward con una variable de entrada.	72

LISTA DE ECUACIONES

	Página
Ecuación 1. Coeficiente de determinación.....	36
Ecuación 2. Error de la raíz cuadrada de la media (RMSE)	37
Ecuación 3. Suavizado de datos	38

LISTA DE ANEXOS

	Página
Anexo A. Datos meteorológicos utilizados en el desarrollo del modelo de predicción	83
Anexo B. Tabla de resultados y convenciones del modelo neuronal previo	119
Anexo C. Tabla de reglas y convenciones del modelo difuso previo	128
Anexo D. Tabla de reglas y convenciones del modelo difuso.	134
Anexo E. Tabla de reglas y convenciones del modelo difuso.....	138

RESUMEN

Muchas de las actividades del ser humano están condicionadas a los cambios de las variables meteorológicas y sus efectos. La radiación solar es la mayor fuente de energía para los seres vivos, por eso se puede afirmar que la estimación de esta es bastante pertinente y más si se tiene en cuenta que su medición es complicada y costosa debido a que la energía solar no es planificable por el comportamiento estocástico de las condiciones climatológicas, además porque los equipos para su medición no se pueden adquirir fácilmente por precio y disponibilidad. Este trabajo presenta el desarrollo de un modelo de predicción de radiación solar usando técnicas basadas en Inteligencia Artificial: Redes Neuronales Artificiales (RNA) y Lógica Difusa, con el fin de alcanzar una mayor precisión de predicción de la radiación solar a la presentada por los modelos estadísticos y físicos comúnmente usados.

Palabras claves: radiación solar, variables meteorológicas, predicción, energía, Redes Neuronales Artificiales, Lógica Difusa, Inteligencia Artificial

ABSTRACT

Many human being activities are conditioned by the changes of the meteorological variables and their effects. Solar radiation is the greatest energy source for living beings, that is why it is possible to say that the estimation of this one is quite complicated and expensive because solar energy is not planned due to the stochastic behavior of weather conditions, furthermore because the equipment for its measurement are not easily acquired because of the price and availability. This project introduces the development of a solar radiation prediction model using techniques based on AI: Artificial Neural Networks (ANN) and Fuzzy Logic, in order to achieve greater prediction accuracy of solar radiation than those given by statistical and physical models commonly used.

Keywords: solar radiation, meteorological variables, prediction, energy, Artificial Neural Networks, Fuzzy Logic, Artificial Intelligence.

Capítulo 1. Generalidades

1.1. Introducción

La necesidad de conocer con exactitud el comportamiento de variables climatológicas para el desarrollo de diversas actividades humanas da como resultado la elaboración de técnicas que permitan estimarlas de manera correcta. Entre estos métodos destacan los estadísticos, matemáticos, físicos y computacionales. Este proyecto se enfoca en los modelos computacionales basados en Inteligencia Artificial, que mediante técnicas de aprendizaje e inferencia prometen resultados interesantes.

La radiación solar es el motor fundamental que influye en el correcto funcionamiento de los procesos atmosféricos y climáticos. La estimación de esta variable es muy pertinente ya que tiene un gran campo de aplicaciones; la radiación solar, por ejemplo, es importante en el diseño de estaciones fotovoltaicas para garantizar la estabilidad de la energía eléctrica generada. En el área agrícola es relevante ya que permite el monitoreo y control del crecimiento de algún cultivo. Sin embargo, la medición de este parámetro es complicada ya que los equipos con los cuales se pueden adquirir los datos son bastante costosos (pirheliómetros y piranómetros) y no se consiguen en todas partes, así que dificulta la posibilidad de tener una base de datos confiable en países poco desarrollados [1]. Por todo lo mencionado anteriormente nace el afán por encontrar la forma más adecuada de estimación de radiación solar.

Los métodos computacionales desarrollados en este proyecto son las Redes Neuronales Artificiales y Lógica Difusa. El primer modelo es bastante útil ya que permite solucionar problemas complejos y no lineales, porque mediante el entrenamiento de la red neuronal este es capaz de aprender el comportamiento de los datos de entrada con respecto a los datos de salida y replicarlo con precisión sin importar si se cambian los datos de entrada para conseguir datos de salida deseados. El segundo modelo también es útil ya que utiliza reglas de inferencia para relacionar los datos de entrada con los de salida mediante reglas, las cuales son establecidas por un experto, quien debe conocer muy bien el comportamiento de los datos. Ambos modelos están basados en Inteligencia Artificial y permiten cumplir con las metas propuestas al desarrollar este proyecto: estimar la radiación solar con variables meteorológicas de fácil adquisición usando algoritmos que puedan remplazar los métodos convencionales.

El documento está organizado de la siguiente forma: en el Capítulo 2 se presenta los factores influyentes en la radiación solar. El Capítulo 3 trata sobre los modelos de predicción. El Capítulo 4 hace referencia al diseño e implementación del modelo neuronal para la predicción de radiación solar. El Capítulo 5 abarca el diseño del otro modelo propuesto, el modelo de inferencia difuso para predicción de radiación solar. En el Capítulo 6 se describen los resultados, conclusiones y trabajos futuros. Al final se relacionan las referencias y los anexos.

Objetivos

1.2.1. Objetivo General

Elaborar un modelo basado en Redes Neuronales Artificiales y Lógica Difusa que permita la predicción de la radiación solar en área urbana de la ciudad de Neiva, teniendo en cuenta parámetros históricos de las variables meteorológicas medidas en la zona objeto de estudio.

1.2.2. Objetivos Específicos

- Adquirir los datos históricos de radiación solar, y de parámetros meteorológicos como: temperatura, humedad relativa, nubosidad, dirección y velocidad del viento, precipitaciones, entre otros, a partir de estaciones meteorológicas cercanas al lugar objeto de estudio. También efectuar un acondicionamiento y tratamiento de las variables de entrada, para ajustarlas en un mismo rango de valores y de esta forma conseguir un procesamiento de datos no sesgado.
- Diseñar los modelos formulados utilizando las técnicas y principios de la inteligencia computacional, las Redes Neuronales Artificiales y Lógica Difusa.
- Desarrollar dichos modelos teniendo en cuenta estudios realizados en proyectos anteriores basados en Redes Neuronales Artificiales y Lógica Difusa, además de otro tipo de técnicas apoyadas en principios de inteligencia artificial.
- Realizar el proceso de validación del modelo a partir de los valores obtenidos del proceso de predicción y los valores medidos en la localidad descrita.

1.3. Justificación y planteamiento del problema

El presente proyecto de grado está orientado al desarrollo de un modelo de predicción de radiación solar por medio de inteligencia computacional en el área urbana de la ciudad de Neiva. El municipio de Neiva (ciudad ubicada en la zona norte del departamento del Huila y capital de este departamento), es muy importante para la región surcolombiana del país debido a una economía muy dinámica basada en el ecoturismo, gastronomía, industria y comercio [2]. Debido a su ubicación cerca de la línea del ecuador y su baja altitud, la ciudad tiene un clima cálido con temperaturas anuales promedio durante el día que van desde 21 hasta 35 grado centígrados. La temperatura de esta zona conserva cierta relación con las lluvias, la época más caliente se sitúa en los meses de agosto y septiembre que son los de menor precipitación atmosférica, cuando la máxima temperatura sobrepasa los 37 °C. Los meses más frescos son los que presentan alternancia de lluvias con calor, como abril, noviembre y diciembre. En este tiempo la temperatura varía entre 28 °C y 30 °C [3].

Las altas temperaturas atraen a muchos turistas nacionales e internacionales que en su mayoría provienen de un clima frío o templado. También el hecho de ser la capital del

departamento donde se puede acceder a municipios cercanos como Rivera y Villavieja, que son muy relevantes por su biodiversidad y ecosistemas, lo cual resulta bastante atractivo.

La agricultura es otra de las actividades que se realizan en el municipio, especialmente los cultivos transitorios y permanentes entre los que se destacan la producción de frijol, maíz, yuca, plátano, cacao, cholupa, café y arroz [4]. Las condiciones climáticas del municipio como lo son las altas temperaturas y alta humedad, debido a los grandes espejos de agua que posee por los ríos que lo cruzan: Magdalena, Las Ceibas y el río de Oro, permiten un buen crecimiento de los cultivos mencionados anteriormente, como la cholupa y el arroz.

También se destaca en el municipio la explotación de petróleo y gas natural, cuyas reservas petroleras representan el 1.2% del país. Se eligió esta zona ya que desde hace algunos años se está presentando una crisis petrolera, la cual llevo a que algunas petroleras recortaran mucho personal, lo que produjo un duro golpe en la economía del municipio [5]. La predicción de radiación solar permite contemplar la opción de implementar energías no convencionales, más específicamente la energía solar, ya que la radiación solar es de gran importancia para el desarrollo de las plantas fotovoltaicas (diseño e implementación). Además, la radiación solar es un dato muy relevante para el análisis de eficiencia y viabilidad de ese tipo de energía, y su predicción es útil para aumentar la base de datos meteorológica y da la oportunidad para ampliar el conocimiento acerca del campo de la climatología.

Se debe agregar que las condiciones climáticas del municipio son las precisas para obtener datos meteorológicos completos ya que Neiva es un municipio está expuesto a microclimas, como todas las zonas del país, pero son menos bruscos comparados con otros municipios, lo cual implica una mejor conservación de los instrumentos de medición y esto lleva a obtener datos más completos y precisos, evitando hacer procedimientos que puedan aumentar la incertidumbre de dichos datos.

De acuerdo con todo lo mencionado anteriormente, la importancia de este trabajo radica en el uso de técnicas de inteligencia computacional como lo son las Redes Neuronales Artificiales y Lógica Difusa ya que pueden manejar grandes cantidades de datos y suministrar predicciones rápidas y apropiadas, con el fin de pronosticar datos de radiación solar que puedan llegar a ser usados en procesos biológicos, meteorológicos, sistemas de producción de energía, uso más eficiente del agua para el riego y mejoramiento de la gestión de los sistemas públicos de iluminación.

Capítulo 2. Factores influyentes en la radiación solar.

El objeto de estudio de este proyecto es la radiación solar, la cual es la energía emitida por el sol que viaja a través del espacio en forma de ondas electromagnéticas y, como se ha mencionado anteriormente, es la mayor fuente de energía para todas las formas de vida terrestres, además de que es un factor fundamental en el análisis del clima y su unidad de medida es el Vatio por unidad de superficie (W/m^2).

Su medición es importante ya que la radiación solar tiene muchas aplicaciones, especialmente como fuente de energía alternativa que permita cambiar los métodos de producción de energía eléctrica basados en la explotación de recursos no renovables [6]. Por esa razón en Colombia se han elaborado Atlas de radiación a lo largo de los años. El Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) es el que ha liderado ese proyecto y lo hace con el fin de aportar conocimiento sobre la radiación solar teniendo en cuenta aspectos como la disponibilidad de esta para el estudio de la dinámica atmosférica y como fuente de energía, también brinda una base de datos meteorológica y métodos para completar series temporales de variables, entre otros [7].

Anteriormente también se indicó que la medición de la radiación solar es costosa y complicada, por esa razón se han desarrollado métodos y modelos para su estimación a partir variables climatológicas de fácil adquisición que permitan cumplir con este objetivo. En este capítulo se van a relacionar proyectos en los cuales se hace mención de los factores que utilizaron para la predicción de la radiación solar.

En el trabajo desarrollado por González A. se evidencia que desarrolla un modelo de predicción de la radiación solar que incide sobre los vehículos solares que compiten en el World Solar Challenge 2013 en cinco localidades cercanas a la carretera donde se lleva a cabo la competencia mediante modelos basados en Redes Neuronales [8]. Realiza el diseño de una red neuronal MADALINE y una red perceptrón multicapa para el aprendizaje de las variables climáticas y la predicción de la radiación en cada uno de los cinco puntos, además de una red neuronal base radial para la aproximación de valores de radiación en puntos intermedios. Las variables climáticas obtenidas por las estaciones meteorológicas son las horas de sol, las precipitaciones, la velocidad del viento, la temperatura máxima, la temperatura mínima y la nubosidad. Luego, mediante correlaciones, identifica que las variables idóneas para realizar una buena predicción son la temperatura máxima, la temperatura mínima y las horas de sol.

Sayago S., Bocco M., G. Ovando y Willington E. desarrollaron seis modelos de redes de tipo perceptrón multicapa con propagación de la información hacia adelante los cuales incluyen una capa de entrada, una capa oculta y una salida que mostraba la radiación solar promedio estimada cada treinta minutos [1]. Los datos de entrada fueron: temperatura, humedad relativa, velocidad del viento y lluvia, obtenidos con una estación meteorológica automática. Se realizó un análisis de correlación con el propósito de obtener una medida de la magnitud

y dirección de la asociación de cada variable de entrada con la radiación solar, obteniendo que la temperatura mínima y la temperatura están muy correlacionadas con la radiación, la humedad relativa no está muy correlacionada y no existe correlación entre las precipitaciones y la radiación solar. Teniendo en cuenta esto último solo uno de los modelos diseñados utilizó todas las entradas, pero todos los modelos utilizaron la temperatura como insumo ya que era la más correlacionada.

Gutiérrez F. propuso la predicción espacial y temporal de la irradiancia global mediante RNA (predicción temporal) y geoestadística (predicción espacial) con el propósito de generar mejores modelos predictivos que ayuden en la estimación de la producción de energía renovable procedente del sol [9]. El modelo neuronal escogido fue el perceptrón multicapa con algoritmo de entrenamiento back propagation. Utilizó cinco variables meteorológicas que son la irradiancia solar global, la temperatura ambiente, la humedad relativa, dirección y velocidad del viento. Adicionalmente agregó cuatro variables meteorológicas calculadas de modo determinista, las cuales son irradiancia solar extraterrestre horizontal, índice de claridad instantánea, distancia al medio día solar y ángulo cenit.

Yadav A., Malik H. y Chandel S.S. presentan en su artículo modelos de predicción de radiación solar basados en redes neuronales artificiales para identificar en que zonas de la India se obtiene una mejor producción de energía solar [10]. Los modelos neuronales utilizados son perceptrón multicapa con algoritmo de entrenamiento LM¹. Los parámetros de entrada identificados son latitud, longitud, temperatura, temperatura mínima, temperatura máxima, altitud y horas de sol. Usan una herramienta llamada WEKA para identificar las variables más relevantes, concluyendo que la longitud y la latitud son las variables menos influyentes en la predicción.

Teniendo en cuenta estos modelos desarrollados se evidencia que las variables meteorológicas comúnmente utilizadas fueron horas de sol, temperatura, temperatura máxima y temperatura mínima. Basándose en el estado del arte se deben tener en cuenta estas variables a la hora de desarrollar los modelos de predicción propuestos sin dar por hecho que estas deben ser los insumos indispensables de dichos modelos planteados.

¹ Algoritmo Levenberg–Marquardt

Capítulo 3. Modelos de predicción.

3.1. Adquisición de datos

Los datos meteorológicos tienen el papel principal en el desarrollo de este proyecto ya que estos datos serán los insumos de los modelos de predicción propuestos.

Debido a lo costoso y desgastante que puede llegar a ser la implementación de una estación meteorológica, se solicitan datos históricos de variables meteorológicas a IDEAM, incluyendo la radiación solar con el fin de analizar cuáles de estas variables serán las más relevantes para el desarrollo de los modelos de predicción.

Los datos ofrecidos por IDEAM provienen de las siguientes estaciones meteorológicas:

Tabla 1. Estaciones Meteorológicas.

Nombre de estación	Departamento	Municipio	Latitud	Longitud	Elevación
Aeropuerto Benito Salas	Huila	Neiva	2°56.0'55.5'' N	75°17.0'35.0'' W	439 m
La Julia			3°05.0'55.6'' N	75°31.0'48.1'' W	1691 m
Palacio Vegalarga			2°56.0'33.5'' N	75°03.0'59.7'' W	1100 m
La Plata			2° 45' 32.9" N	75° 04' 28.4" W	2101 m

La estación meteorológica con la base de datos más completa es el Aeropuerto Benito Salas. Ofrece datos diarios de las siguientes variables: temperatura máxima (°C), temperatura mínima (°C), humedad relativa (%), tensión de vapor (mbar), punto de rocío (°C), horas de brillo solar (número de horas), velocidad (m/s) y dirección del viento, precipitación (mm²), nubosidad (Octas³), evaporación (mm), recorrido del viento (Km). También ofrece datos horarios de las siguientes variables: horas de brillo solar, velocidad y dirección del viento. La base de datos de todas las variables meteorológicas inicia el 1 de enero del 2007 y terminal el 31 de diciembre del 2017. Con respecto a la radiación solar, esta estación ofrece datos diarios, pero desde marzo del 1993 hasta diciembre del 2003.

La estación meteorológica La Julia ofrece datos diarios de las siguientes variables: humedad relativa (agosto 1987 – mayo 2017), precipitaciones (diciembre 1986 – mayo 2017), temperatura mínima (enero 1998 – mayo 2017), temperatura máxima (agosto 1990 – mayo del 2017) y temperatura media (agosto 1987 – mayo 2017); además ofrece datos del recorrido (enero 1997 – septiembre 1998), velocidad y dirección del viento (enero 1997).

² Milímetros de agua.

³ Octas de cielo cubierto.

La estación meteorológica Palacio Vegalarga ofrece datos diarios de las siguientes variables: horas de brillo solar (enero 1997 – enero 2017), evaporación (marzo 1978 – diciembre 2016), humedad relativa (octubre 1978 – diciembre 2016), precipitación (noviembre 1971 – diciembre 2016), temperatura media (enero 1979 – diciembre 2016), temperatura máxima (enero 1979 – diciembre 2016), temperatura mínima (enero 1979 – diciembre 2016) y recorrido del viento (octubre 1985).

La estación meteorológica La Plata ofrece solamente datos horarios de radiación solar global desde enero de 2005 hasta diciembre de 2016. Esta estación es la única que ofrece datos actualizados de radiación solar.

Aunque todas las estaciones cuentan con periodos de tiempo (meses e incluso años) en los cuales no fue posible tomar datos, la estación meteorológica con la base de datos más completa y que ofrece mayor cantidad de variables meteorológicas es el Aeropuerto Benito Salas. El mayor inconveniente que presenta esta estación es que la base de datos de radiación solar está incompleta y desactualizada.

Con el fin de dar solución a este problema se propone que los datos de entrada (insumos) de los modelos se tomen de la base de datos ofrecida por el Aeropuerto Benito Salas y los datos de radiación solar se tomen de la estación La Plata.

Cabe aclarar que también se intentó conseguir bases de datos meteorológica provenientes de otras organizaciones. Por ejemplo, se pasó una solicitud a World Radiation Data Center (WRDC) y a World Meteorological Organization (WMO) para tener acceso a las bases de datos meteorológicas de Neiva, pero los datos que ofrecían eran los mismos que suministró IDEAM ya que esas organizaciones mundiales acuden a las entidades locales para reunir todas las bases de datos y consolidarlas.

Otra opción que se tuvo en cuenta fue enviar la solicitud a NASA. Estos suministraron una base de datos muy completa con datos como: insolación incidente en superficie horizontal, insolación de la parte superior de la atmósfera, presión atmosférica, temperatura mínima, temperatura máxima, humedad relativa, punto de rocío, precipitación, entre otros. El problema con esta base de datos es que se obtiene a partir de imágenes satelitales y para seccionar una gran cantidad de zonas, usan una grilla de $1/2^\circ$ de latitud por $1/2^\circ$ de longitud, quiere decir que cada sección tiene un área de $3077,16 \text{ Km}^2$, teniendo en cuenta que Colombia está sobre el meridiano del ecuador [11]. Esto implica que los datos que componen esa base no son precisos, ya que cada sección pueda que abarque más de un municipio, incluso se puede pensar que algunos departamentos queden divididos en dos o tres secciones, lo que dificulta la precisión de la predicción. Una solución sería interpolar los datos cada 0.05° con el fin de obtener más precisión en las mediciones de un punto coordenado, pero debido a que los datos meteorológicos son estocásticos no habría una función que describa su comportamiento y con la cual se pueda realizar una interpolación confiable de los datos. De existir esta función no habría necesidad de realizar predicciones. Por esa razón la opción de trabajar con los datos brindados por NASA fue descartada para el desarrollo del proyecto.

Estandarización de los datos de entrada

Anteriormente se indicó que las bases de datos de las estaciones meteorológicas escogidas también tenían datos incompletos. El Aeropuerto Benito Salas presenta muy pocos datos incompletos, se podría decir que son días aislados, en cambio La Plata presenta varios días en los cuales no se tienen mediciones de la radiación solar. Teniendo en cuenta esto se debe asegurar que, en primer lugar, los datos de entrada y salida de los modelos estén en el mismo formato de tiempo, ya sean diarios u horarios; en segundo lugar, se debe buscar la forma de completar las bases de datos para que esas series temporales sin mediciones, con valor cero, no afecten la predicción.

Debido a que los datos provenientes de la estación meteorológica del Aeropuerto Benito Salas son diarios y los datos que ofrece la estación meteorológica La Plata son horarios se debe encontrar la forma de estandarizarlos. Se debe considerar que es más sencillo y menos contraproducente establecer todas las bases de datos como diarios; de hacerlo de forma opuesta, implicaría realizar aproximaciones de veinticuatro datos a partir de uno solo lo que produciría que el error en la predicción se aumente y estos datos sean menos precisos. Considerando todo lo anterior se toma la decisión de convertir la base de datos horarios de radiación solar en diarios. Para homogeneizar las series de radiación solar, se calcula el valor diario de radiación solar de la estación La Plata realizando el acumulado o la suma horaria durante las 24 horas del día, es decir, se suman todos los registros horarios durante cada día entre las 06:00 y las 19:00 horas, ya que según IDEAM, estos datos se encuentran validados y con el coeficiente de calibración, y de esa forma obtener los valores diarios de radiación. Este proceso se llevó a cabo por recomendación del señor José David Garavito Mahecha quien trabaja en la Subdirección de Meteorología de IDEAM y fue la persona quien envió los datos meteorológicos solicitados.

Al tener las bases de datos de entrada y de salida ya homogeneizadas, se busca la forma de completar las series temporales que no cuentan con mediciones. Para completar bases de datos meteorológicas algunos proponen varios métodos. A. Eric y S. Javier proponen dos métodos interesantes [12]: el primero se basa en la descomposición en componentes principales de la matriz de correlación de datos de una misma variable entre estaciones cercanas y en periodos de tiempo comunes; el segundo método es para ser utilizado cuando no hay estaciones cercanas y el rellenado se debe hacer con la información de la misma estación, y consiste en ajustar un modelo autorregresivo a la serie de tiempo y utilizar ese modelo como estimador de los datos ausentes. En otros documentos se proponían otros dos métodos [13]: el de regresión lineal y el de la razón normal. También, en otros documentos mencionaban nuevamente la interpolación de datos y el uso de filtros predictivos. Después de evaluar todo lo mencionado anteriormente, se toma la decisión de eliminar esos días incompletos de las bases de datos ya que se propone una predicción de datos meteorológicos y no tendría sentido realizar una predicción de datos estimados porque la predicción no estaría basada en datos reales y la precisión de estos resultados podría ser dudosa. Los datos de radiación solar son los que presentan mayores vacíos en sus series temporales, además del hecho de ser la variable de interés en el proyecto, se toma esta variable como referencia para la eliminación de datos. Primero se hace una revisión de toda la serie temporal de radiación

solar y se verifica que el periodo de tiempo en los cuales presenta mediciones constantes es del 1 de febrero de 2013 hasta el 30 de septiembre de 2016, por lo tanto, se toma este periodo de tiempo de todas las variables como base de datos para el desarrollo de los modelos propuestos. Luego, con ayuda del software Matlab se realiza la búsqueda en la matriz de datos de todos los valores de radiación menores a 10 y los días a los cuales pertenecen, estos datos se eliminan de la matriz de radiación solar. Para que la eliminación de datos sea homogénea con respecto a las otras variables, se toman los días a los cuales correspondían esos valores bajos de radiación, se hace la búsqueda de esos días en las series temporales de las otras variables y se eliminan también los datos medidos de esos días.

3.2. Variables relevantes

Para identificar cuáles de las variables ofrecidas por la estación meteorológica que se tomó como referencia son las más relevantes, se realizaron algunos procedimientos en los cuales se tuvo que considerar aspectos como la relación que existe entre esas variables y la radiación solar, y la disponibilidad de datos.

Primero, con ayuda de Matlab, se identifica cual es la relación existente entre las variables meteorológicas y la radiación solar. Para ello se calcula el coeficiente de correlación de Pearson, el cual mide el grado de covarianza entre distintas variables relacionadas linealmente [14]. Lo anterior no quiere decir que el cálculo de este coeficiente defina cuales son las variables más relevantes y más influyentes, pero sí dará una idea de que tan relacionadas están las variables que se van a tomar como insumos de los modelos de predicción con la radiación solar, que es el target. En la Tabla 2, se relacionan los resultados obtenidos en Matlab.

Tabla 2. Coeficiente de Correlación de Pearson calculado en Matlab.

Variables Meteorológicas	r	P-valores	Límite inferior	Límite superior
Temperatura máxima	0.3098	0	0.2605	0.3575
Temperatura mínima	-0.0332	0.2244	-0.0867	0.0204
Humedad Relativa	-0.1475	0	-0.1995	-0.0947
Tensión de Vapor	-0.0565	0.0389	-0.1097	-0.0029
Punto Rocío	-0.0484	0.0769	-0.1017	0.0052
Horas de Brillo Solar	0.3990	0	0.3529	0.4431
Velocidad del Viento	-0.0207	0.4494	-0.0742	0.0329
Precipitación	-0.1883	0	-0.2395	-0.1361
Nubosidad	0.2361	0	0.1848	0.2861
Evaporación	-0.0228	0.4040	-0.0763	0.0308
Recorrido del Viento	-0.0657	0.0163	-0.1188	-0.0121

El valor del coeficiente de Pearson se encuentra dentro de un rango entre -1 y 1. En algunos textos representan el coeficiente de Pearson de la forma r , otros lo representan como ρ_{xy} y algunos otros como r_{xy} . En este libro se simbolizará como r . Los resultados posibles del

coeficiente de Pearson son: si $r = 1$ existe una correlación positiva perfecta, si $0 < r < 1$ existe una correlación positiva, si $r = 0$ no existe relación lineal, si $-1 < r < 0$ existe una correlación negativa, si $r = -1$ existe una correlación negativa perfecta [15].

Teniendo en cuenta los textos y artículos referenciados sobre este tema, se observa que las variables que presentan un coeficiente de correlación mayor a cero son: horas de brillo solar, temperatura máxima y nubosidad; entre más cercano a 1 sea el valor del coeficiente de Pearson hay relación directa entre las dos variables. Las variables que presentan un coeficiente de correlación cercano a cero son: temperatura mínima, tensión de vapor, punto de rocío, velocidad del viento, evaporación y recorrido del viento; entre más cercano a 0 sea el valor del coeficiente de Pearson hay menor relación lineal entre las variables, pero no implica que dichas variables sean independientes ya que puede existir una relación no lineal entre ellas. Por último, las variables que presentan un coeficiente menor a cero son: humedad relativa y precipitación; entre más cercano a -1 sea el valor del coeficiente de Pearson hay una relación inversa entre las dos variables.

En la Tabla 2 también se relacionan los P-valores, los cuales son datos que ofrece el coeficiente para probar la hipótesis de que no existe relación entre los fenómenos observados. Si los P-valores son menores al nivel de significancia (denominado Alfa, cuyo valor predeterminado es 0.05), la correlación correspondiente se considera significativa, esto quiere decir que se rechaza la hipótesis de independencia y se asume que las dos variables están relacionadas. Revisando la tabla, se puede observar que las variables que presentan los P-valores menores al nivel de significancia son: temperatura máxima, humedad relativa, tensión de vapor, horas de brillo solar, precipitación, nubosidad y recorrido del viento. Lo anterior indica que esas variables meteorológicas poseen una relación significativa con la radiación solar; pero si se tienen en cuenta los intervalos de confianza de cada variable con respecto a la radiación solar, revisando los límites superior e inferior, tensión de vapor y recorrido del viento pueden tener un coeficiente de Pearson de cero, lo cual hace que su relación con la radiación solar no sea lineal.

Además del coeficiente de Pearson se proponen otros métodos para identificar las variables relevantes utilizando el software WEKA⁴ (Waikato Environment for Knowledge Analysis). Este software fue diseñado en la Universidad de Waikato de Nueva Zelanda, desarrollado en Java y permite acceder a librerías de machine learning, aprendizaje automático y minería de datos.

En el explorador de WEKA se puede encontrar clasificadores, clusters, seleccionadores de atributos, entre otras herramientas muy útiles para aplicaciones en las cuales se necesite un análisis profundo de datos.

⁴ <https://www.cs.waikato.ac.nz/ml/weka/>



Figura 1. Pantalla de inicio de WEKA.

Se utilizaron las siguientes técnicas para identificar que variables son más relevantes a la hora de estimar la radiación solar:

CFsSubsetEval

El primer método utilizado fue el evaluador de atributos CFsSubsetEval (Evaluador de selección de funciones basada en correlación) con método de búsqueda BestFirst y Cross-Validation de 10 folds. No se realizó ningún preprocesamiento de datos. Es un algoritmo de filtro simple que clasifica los subconjuntos de características de acuerdo con una función de evaluación heurística basada en correlación.

Evalúa el valor de un subconjunto de atributos al considerar la capacidad predictiva individual de cada característica junto con el grado de redundancia entre ellas. Se prefieren los subconjuntos de características que están altamente correlacionados con la clase o variable de interés mientras que tienen una baja correlación entre ellas.

El método de búsqueda BestFirst busca en el espacio de subconjuntos de características mediante la codiciosa escalada aumentada con una instalación de retroceso.

Se utiliza Cross-Validation para calcular el porcentaje de aciertos esperado haciendo una validación cruzada de 10 hojas, en este caso, esto hace que la evaluación sea 10 veces más lenta pero más precisa.

Este método calcula una medida heurística del "mérito" de un subconjunto de características a partir de correlaciones de esas características por pares. Esta búsqueda heurística se utiliza para atravesar el espacio de subconjuntos de características en menor tiempo razonable. Se informa el subconjunto con el mayor mérito encontrado durante la búsqueda [16]. Los resultados obtenidos se mencionan a continuación.

Tabla 3. Evaluador de atributos *CFsSubsetEval*, método de búsqueda *BestFirst* y *Cross-Validation* de 10 folds.

number of folds	(%)	attribute
0	0%	1 Temperatura Máxima
0	0%	2 Temperatura Mínima
0	0%	3 Humedad Relativa
0	0%	4 Tensión Vapor
0	0%	5 Punto Roció
10	100%	6 Horas Brillo Solar
10	100%	7 Velocidad Viento
0	0%	8 Precipitación
0	0%	9 Nubosidad
0	0%	10 Evaporación
0	0%	11 Recorrido Viento

Este es un método de búsqueda muy básico ya que al revisar detenidamente los resultados se ve las variables seleccionadas son horas de brillo solar y velocidad del viento, pero deja de lado variables como temperatura máxima que, según las investigaciones relacionadas en la bibliografía de este libro, es un atributo relevante.

ReliefFAttributeEval

El segundo método que se usó fue el evaluador de atributos *ReliefFAttributeEval* con método de búsqueda *Ranker* y *Cross-Validation* de 10 folds. No se realizó ningún preprocesamiento de datos.

Este método evalúa el valor de un atributo muestreando repetidamente una instancia y considerando el valor del atributo dado para la instancia más cercana de la misma clase y diferente. La idea clave del método es estimar atributos de acuerdo a qué tan bien sus valores distinguen entre instancias que están cerca unas de otras [17].

El método de búsqueda *Ranker* clasifica los atributos por sus evaluaciones individuales.

Como se mencionó anteriormente, se utiliza *Cross-Validation* para calcular el porcentaje de aciertos esperado haciendo una validación cruzada de 10 hojas, en este caso, esto hace que la evaluación sea 10 veces más lenta pero más precisa.

Weka ofrece dos datos: el average merit (y su desviación típica) y el average rank (y su desviación típica). El average merit se refiere a la media de las correlaciones. El average rank se refiere al orden medio en el que quedó cada atributo.

A continuación, se relacionan los resultados obtenidos.

Tabla 4. Evaluador de atributos ReliefFAttributeEval, método de búsqueda Ranker y Cross-Validation de 10 folds.

average merit	average rank	attribute
0.003 +- 0.001	1 +- 0	6 Horas Brillo Solar
0.002 +- 0	2.5 +- 0.5	9 Nubosidad
0.002 +- 0	2.5 +- 0.5	2 Temperatura Mínima
0.001 +- 0	4 +- 0	5 Punto Rocío
0.001 +- 0	5.3 +- 0.46	4 Tensión Vapor
0.001 +- 0	6.2 +- 0.87	11 Recorrido Viento
0 +- 0.001	7.3 +- 1.35	7 Velocidad Viento
0 +- 0	7.9 +- 1.04	10 Evaporación
(-0) +- 0	9.1 +- 0.83	1 Temperatura Máxima
(-0) +- 0	9.2 +- 0.87	3 Humedad Relativa
(-0.002) +- 0	11 +- 0	8 Precipitación

Según los resultados arrojados por WEKA, Avg merit es el peso relativo del atributo con sus márgenes de error y Avg Rank es la posición del atributo de media en los folds. Según este resultado los atributos más relevantes son horas de brillo solar, nubosidad y temperatura mínima. Los atributos menos relevantes son temperatura máxima, humedad relativa y precipitación. Se identifica que este método obtiene valores más pertinentes, pero aun así deja duda que variables como temperatura máxima y humedad relativa no cuenten con mayor relevancia.

Asimismo, se utilizó este evaluador de atributos aplicando a los datos un filtro que convierte los datos numéricos en nominales (Filtro NominalToBinary) con método de búsqueda Ranker y Cross-Validation de 10 folds y los resultados obtenidos se relacionan a continuación.

El filtro NominalToBinary convierte todos los atributos nominales en atributos numéricos binarios. Un atributo con k valores se transforma en k atributos binarios si la clase es nominal, utilizando el enfoque de un atributo por valor.

Tabla 5. Evaluador de atributos ReliefFAttributeEval, con filtro aplicado.

average merit	average rank	attribute
0.702 +- 0.006	1.3 +- 0.9	7 Velocidad Viento
0.7 +- 0.006	3.1 +- 1.14	4 Tensión Vapor
0.699 +- 0.006	3.5 +- 0.92	11 Recorrido Viento
0.699 +- 0.006	3.7 +- 1.68	1 Temperatura Máxima
0.699 +- 0.007	4 +- 1.48	6 Horas Brillo Solar
0.698 +- 0.007	5.5 +- 0.92	5 Punto Rocío

0.694 +- 0.007	6.9 +- 0.3	10 Evaporación
0.691 +- 0.007	8.4 +- 0.49	2 Temperatura Mínima
0.691 +- 0.007	8.6 +- 0.49	3 Humedad Relativa
0.584 +- 0.005	10 +- 0	9 Nubosidad
0.432 +- 0.005	11 +- 0	8 Precipitación

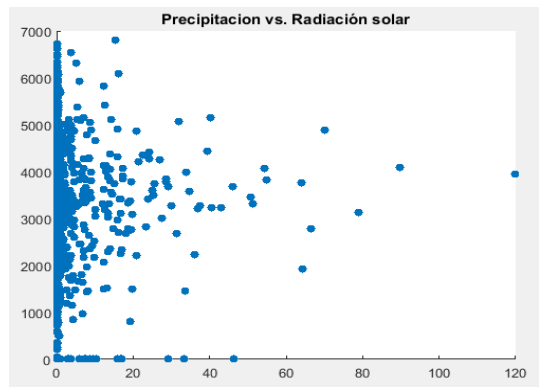







Según el resultado, las variables más relevantes son velocidad del viento, tensión de vapor y recorrido del viento. Los atributos menos relevantes son humedad relativa, nubosidad y precipitación. Si se comparan ambos métodos, estos coinciden en que la precipitación es la variable menos relevante, pero no coincide con respecto a los otros atributos como horas de brillo solar, nubosidad y velocidad del viento.

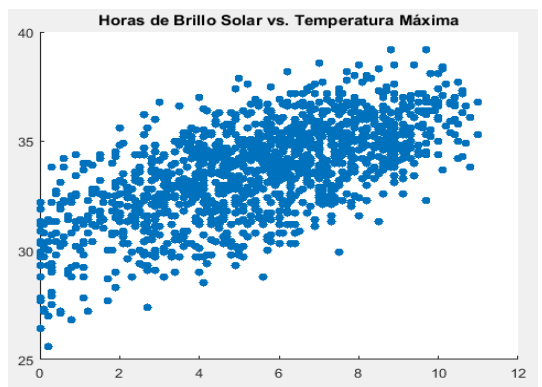


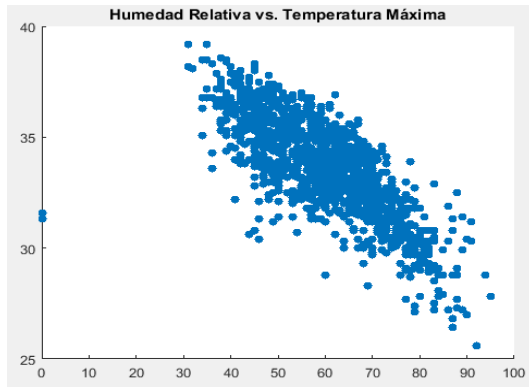
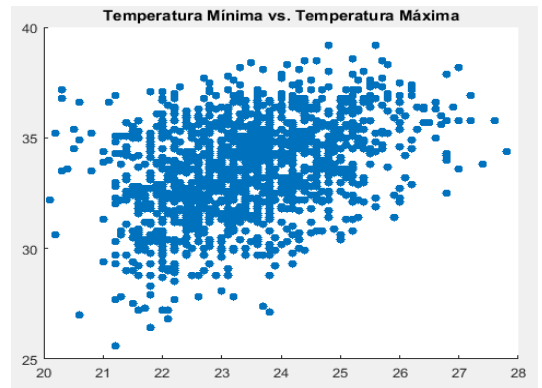
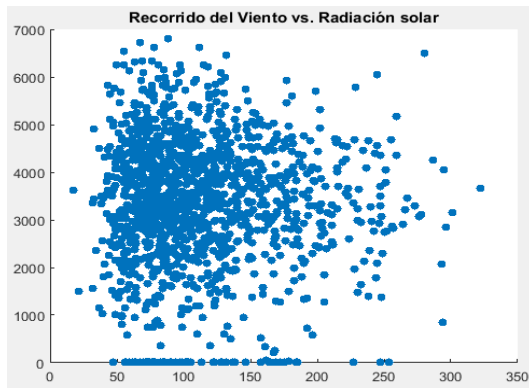

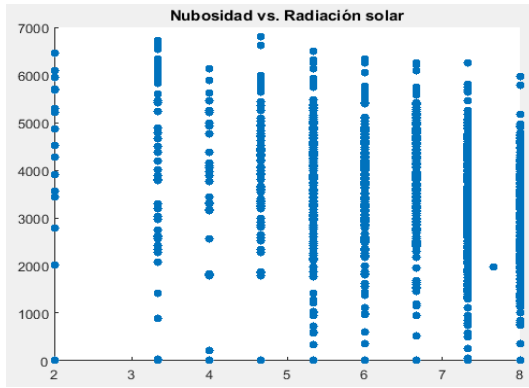
Por último, se hace uso de diagramas de dispersión con la ayuda de Matlab para facilitar la interpretación y visualización de datos, además de verificar si existe relación entre las variables meteorológicas que se pretenden utilizar como insumos del modelo de predicción, lo anterior con el fin de evitar que se presente multicolinealidad, donde dos o más variables explicativas independientes están fuertemente correlacionadas entre sí. En la Figura 2 se presentan los diagramas de dispersión.


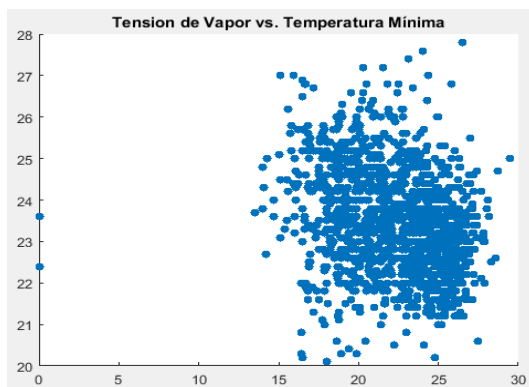

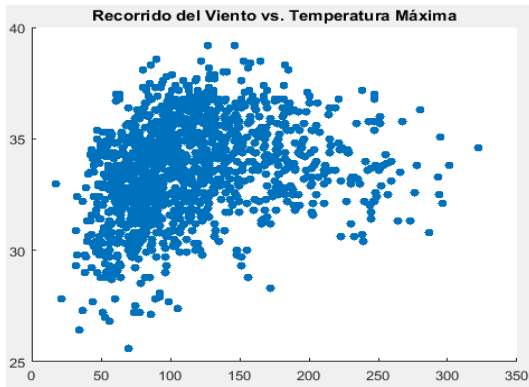
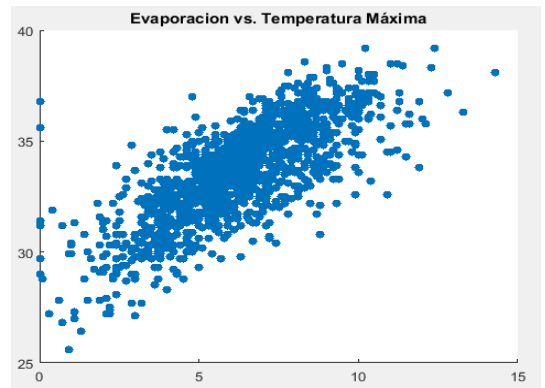
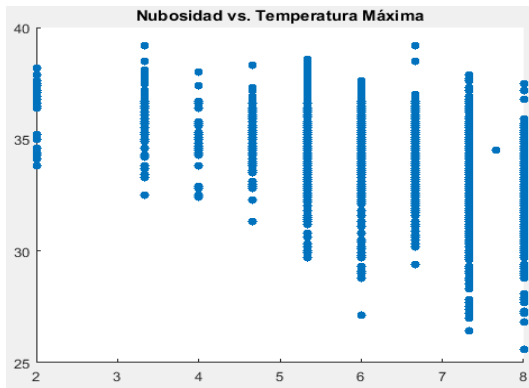
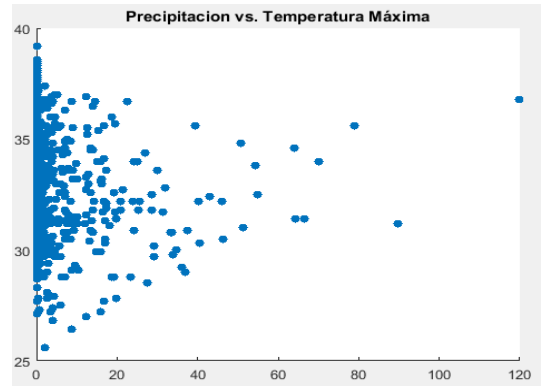

Teniendo en cuenta los resultados del coeficiente de Pearson y de los métodos aplicados con la ayuda del software WEKA, se puede apreciar que las horas de brillo solar es una variable clave que se debe tener en cuenta en el modelo porque presenta buenos resultados en todas las técnicas aplicadas. También la nubosidad y la temperatura máxima presentan una relación directa con la radiación solar, teniendo en cuenta el coeficiente de Pearson y el evaluador de atributos ReliefFAttributeEval (sin usar el filtro para la nubosidad y con el filtro aplicado para la temperatura máxima).

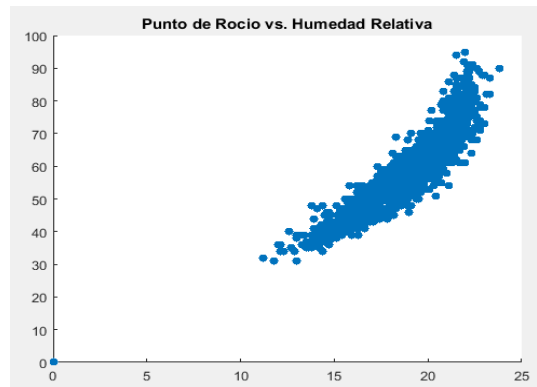
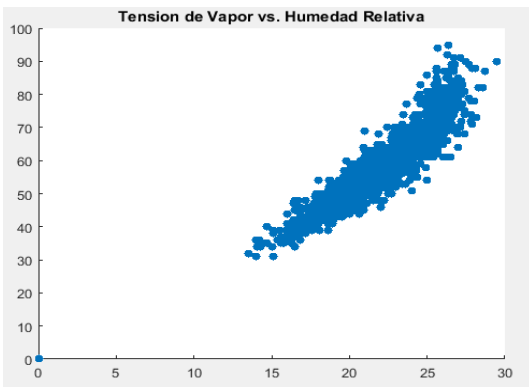

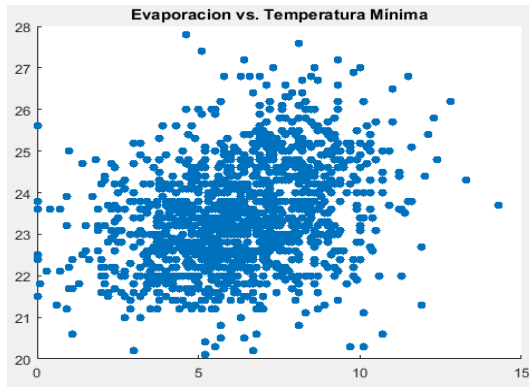
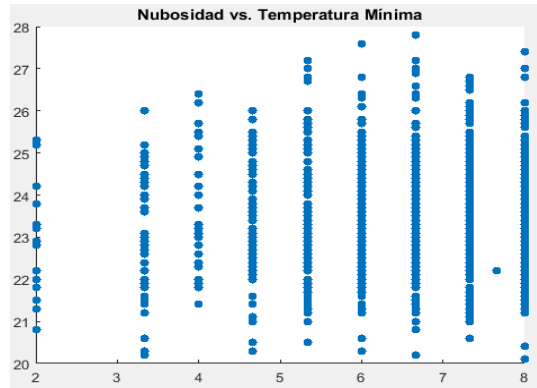
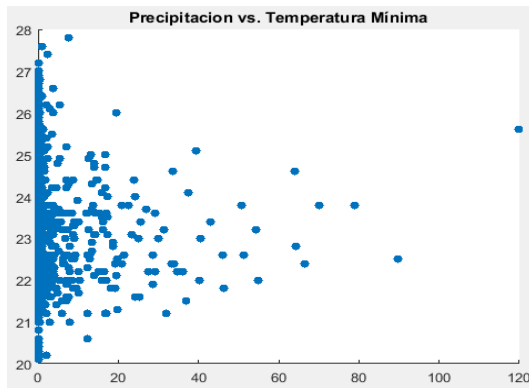
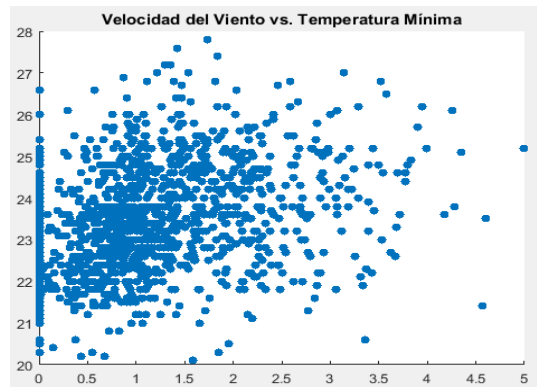
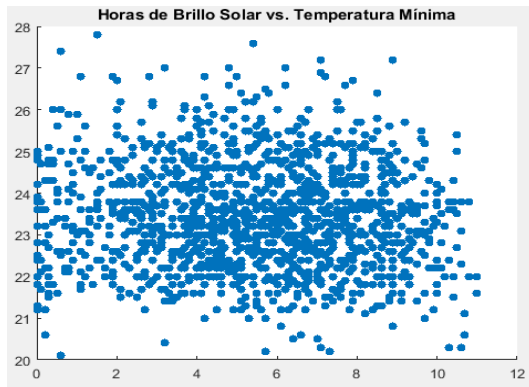
Otras variables como humedad relativa y precipitaciones presentan una relación inversa con la radiación solar, pero es más sutil comparada con las otras variables mencionadas anteriormente. Según los resultados conseguidos por los métodos aplicados en WEKA, estas dos variables no presentan mucha relevancia en comparación a las demás.









Con respecto a las otras variables, estas presentan un coeficiente de correlación de Pearson cercano a 0 lo que indica que no tienen correlación lineal con la radiación solar, pero si se analizan los resultados de las técnicas utilizadas a partir de WEKA, el punto de rocío y la evaporación son variables poco relevantes y por esa razón se descartan. La velocidad del viento muestra relevancia en dos de los métodos implementados en el software ya mencionado. Se verifica también que la temperatura mínima es relevante para el evaluador de atributos ReliefFAttributeEval sin aplicar algún filtro a los datos, además esta variable es una de las más usadas en los modelos de predicción de los proyectos tomados como referencia en el Capítulo 2 pero para los otros métodos no se considera relevante.



























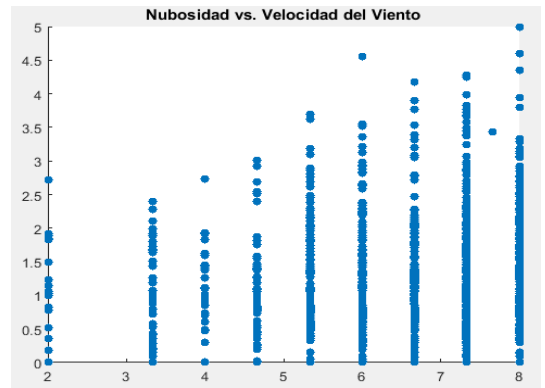
















Figura 2. Gráficas de dispersión

Al revisar las gráficas de dispersión se puede afirmar que variables como punto de rocío y tensión de vapor tienen mucha relación entre ellas, también la humedad relativa presenta relación con variables meteorológicas como evaporación, tensión de vapor y punto de rocío. Estas variables mencionadas no es conveniente tenerlas en el mismo grupo de variables explicativas del modelo ya que podría presentarse multicolinealidad.

Al revisar todos los métodos aplicados anteriormente para la identificación de variables relevantes se pueden destacar las siguientes: horas de brillo solar, velocidad del viento, nubosidad, temperatura mínima, tensión de vapor, recorrido del viento, temperatura máxima, humedad relativa y precipitación. Pero al confrontar el comportamiento de cada una de estas variables con la radiación solar, según las gráficas de dispersión, la única que muestra algún tipo de relación visible con la radiación solar es horas de brillo solar (lineal). Temperatura máxima también muestra algún tipo de relación (lineal) con radiación solar pero la relación que presenta horas de brillo solar es mayor, además, todos los métodos coinciden que horas de brillo solar es una variable relevante.

De manera inicial e intuitiva se tomaron como variables de entrada de los modelos de predicción: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones. Luego de realizar el análisis de las variables según los métodos aplicados anteriormente, se llega a la conclusión que se va a utilizar horas de brillo solar como única variable de entrada de los modelos finales de predicción, esto también es conveniente en el sentido que el mejor modelo es el más sencillo y el que ofrece mejores resultados. En el Anexo A se relacionan los datos de las variables meteorológicas tomadas para desarrollar los modelos de predicción.

3.3. Validación de resultados

Para identificar si las predicciones realizadas por los modelos propuestos son pertinentes y reflejan el correcto diseño y desarrollo de los mismos, se debe hacer uso de funciones estadísticas que permitan entender que tan eficaces son los modelos de predicción elaborados y si las estimaciones de radiación solar realizadas se pueden llegar a utilizar con confianza

en otros procesos donde se requieran, como procesos físicos, biológicos, generación de energía fotovoltaica, complementación de bases de datos meteorológicas, entre otros.

En el presente proyecto se hace uso del coeficiente de determinación, con el cual se busca medir la bondad del ajuste o fiabilidad del modelo a los datos reales. La bondad de la predicción depende de la relación entre las variables; si no hay covarianza entre las variables relacionadas, no se podrían realizar estimaciones de datos válidas, y si la intensidad de la covarianza es moderada, entonces las predicciones no serán confiables.

El coeficiente de determinación se representa por R^2 indica cuál es la proporción de la variación total en la variable a predecir, que es explicada por el modelo de regresión estimado, es decir, mide la capacidad explicativa del modelo estimado [18]. Cuanto mayor sea la proporción de la variación total, mejor será la predicción. Si llegara a ser igual a 1, las predicciones serían “exactas”, no tendrían error.

Este coeficiente no sólo mide la capacidad explicativa de un modelo, sino que, además, permite elegir entre varios modelos cuál es el más adecuado. Así si los modelos tienen la misma variable dependiente (variable que se va a predecir) y el mismo número de variables explicativas (variables que predicen), será más adecuado el que tenga un coeficiente de determinación mayor [18].

En el proyecto llamado “Radiación Solar Horaria: Modelos De Estimación A Partir De Variables Meteorológicas Básicas” [1], también se hace uso del coeficiente de determinación como una forma de medir el desempeño de los modelos propuestos. Esto indica que el coeficiente de determinación es un buen indicador del rendimiento de modelos de predicción. Para calcular el coeficiente de determinación se hará uso de la Ecuación 1.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \text{ Ecuación 1.}$$

Además del coeficiente de determinación, se realiza la validación de resultados por medio del Error de la raíz cuadrada de la media (RMSE), el cual consiste en la raíz cuadrada de la sumatoria de los errores cuadráticos. El RMSE es una medida cuantitativa del desempeño utilizada comúnmente para evaluar métodos de pronóstico.

Es una medida de precisión, para comparar los errores de predicción de diferentes modelos para un conjunto de datos en particular y no entre conjuntos de datos que ya dependen de la escala. Esta medida siempre toma un valor positivo, un valor de 0 indicaría un ajuste perfecto de los datos.

El RMSE indica el ajuste absoluto del modelo de los datos, cuán cerca están los puntos de datos observados de los valores predichos del modelo. En los proyectos llamados “Radiación Solar Horaria: Modelos De Estimación A Partir De Variables Meteorológicas Básicas” [1] y “Modelo Para La Predicción De La Radiación Solar A Partir De Redes Neuronales

Artificiales” [8] también hacen uso del RMSE para la validación de los resultados. Para calcular el RMSE se hará uso de la Ecuación 2.

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (Valor\ real_i - Valor\ estimado_i)^2} \quad \text{Ecuación 6.}$$

Además, se ilustran gráficas comparativas entre los valores de radiación solar estimados y los valores de radiación solar medidos para poder identificar fácilmente la fidelidad de la predicción. Los datos utilizados para validación de resultados serán especificados más adelante, en los capítulos definidos para el diseño y desarrollo de cada modelo propuesto.

3.4. Modelos propuestos inicialmente

De manera inicial se desarrollaron dos modelos de predicción de radiación solar, los cuales no cumplieron con las expectativas pero fueron bastante útiles en el sentido que trazaron la ruta adecuada para la elaboración de los modelos funcionales de predicción.

3.4.1. Modelo neuronal previo

Para este modelo se desarrollaron tres submodelos, los cuales tienen en común su topología, pero se diferencian en el número de entradas, las variables meteorológicas que se utilizaban como insumos del modelo y el número de neuronas en las capas ocultas. Como entradas del primer submodelo se escogieron las siguientes variables meteorológicas: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones; para el segundo submodelo las variables fueron: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa; para el último submodelo se escogieron las horas de brillo solar, la nubosidad y la humedad relativa.

Con ayuda del software Matlab se desarrolló el modelo de predicción de radiación solar mediante RNA. Se planteó un modelo neuronal feed-forward backpropagation con algoritmo de entrenamiento LM. El modelo presentaba una capa de entrada, dos capas ocultas y una capa de salida, como se muestra en la Figura 3. La función de activación escogida para las capas ocultas fue Tangente Sigmoides. La función de activación usada en la capa de salida fue la lineal.

Debido a que los datos de entrada y salida pueden contener ruido, se propone la Ecuación 3 para suavizarlos. El problema con esta función es que realiza un suavizado bastante agresivo, como se ve reflejado en la Figura 4. De esta forma el modelo neuronal puede realizar la predicción fácilmente ya que dejan de ser datos estocásticos y se convierten en datos descritos por una función que la red neuronal puede aprender. Se debe indicar que no fue posible retroceder el proceso de suavizado ni regresarlos a las escalas normales, así que son datos poco confiables que no pueden ser utilizados ni aplicados en ningún proceso. Para validar los

resultados solo se tuvo en cuenta el coeficiente de determinación (R^2), además de la comparación del comportamiento de los datos reales y los datos estimados.




Figura 3. Diagrama del modelo de predicción neuronal previo con cinco variables de entrada, dos capas ocultas de ochenta y veinte neuronas cada una, y una capa de salida.

$$y(n) = \frac{y(n) + y(n-1)}{n+1} \quad \text{Ecuación 11.}$$

El modelo fue capaz de conseguir un valor de R^2 o una bondad de ajuste de 0.93, o también expresado de otra forma, se obtuvo un 93% de la variabilidad de radiación solar explicada por la variabilidad de las variables de entrada, en este caso cinco variables (segundo submodelo).

En la Figura 5 se muestran los datos reales y los datos estimados. Se observa que los datos estimados siguen una tendencia, tienen un comportamiento similar a los datos reales de radiación solar, además del hecho que se obtuvo un coeficiente de determinación bueno, pero como se especificó anteriormente este resultado no es útil ya que no se encontró la forma de retroceder el proceso de suavizado, por esa razón se llegó a la conclusión de que no es un modelo funcional. En el Anexo B del libro se adjunta la tabla de resultados del modelo neuronal descrito anteriormente.




Figura 4. Datos suavizados de radiación solar.




Figura 5. Resultados modelo neuronal previo.

3.4.2. Modelo difuso

Para el modelo de predicción con lógica difusa se utilizaron como variables de entrada: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones. No se suavizaron los datos. Se utilizó el cálculo de R^2 para medir la precisión del modelo. En la Figura 6 se muestra el diagrama del modelo fuzzy previo.

Con ayuda del software Matlab se desarrolló el modelo de predicción de radiación solar mediante lógica difusa. Se planteó un modelo fuzzy con 106 reglas, con tres y cinco funciones de membresía, según una valoración de la distribución de datos, la cual indicó que para las variables de horas de brillo solar, precipitaciones y radiación solar necesitaban cinco funciones de membresía, las cuales eran: trapezoidales en los extremos, gaussianas en los medios y en el centro triangular; para las otras cuatro variables se plantearon tres funciones de membresía, las cuales eran: trapezoidales en los extremos y triangular en el centro.

Las cuatro primeras reglas solo utilizaron las horas de brillo solar y la radiación solar, en las otras 102 reglas se utilizaron todas las variables.

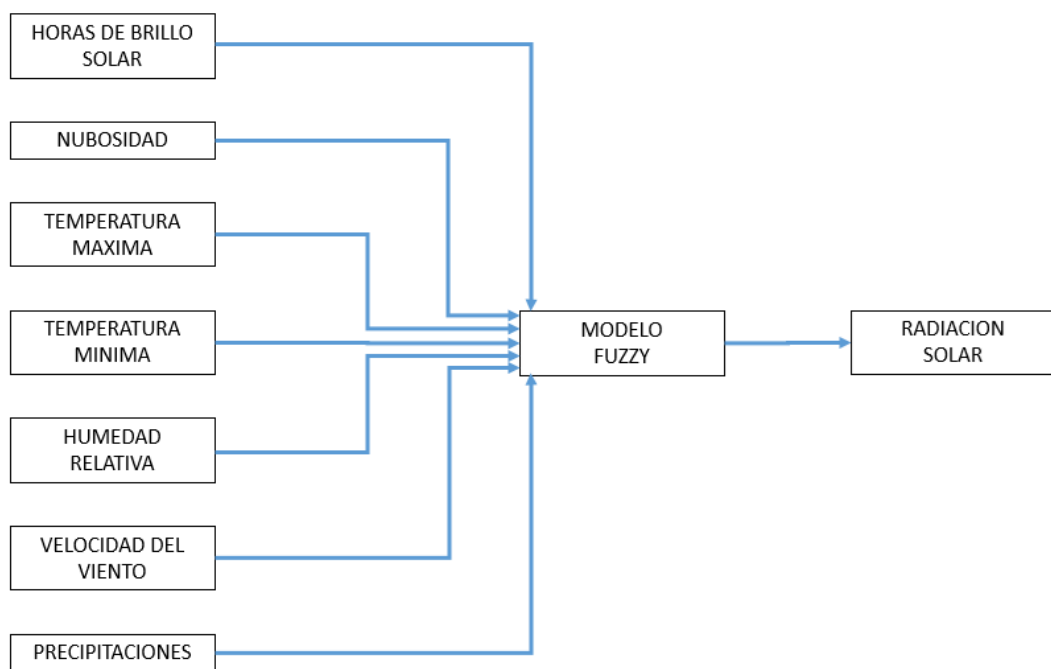


Figura 6. Diagrama del modelo Fuzzy.

En las figuras que se presentan a continuación se muestran las funciones de membresía aplicadas a cada variable del modelo difuso.




Figura 7. Funciones de membresía de horas de brillo solar.




Figura 8. Funciones de membresía de nubosidad.

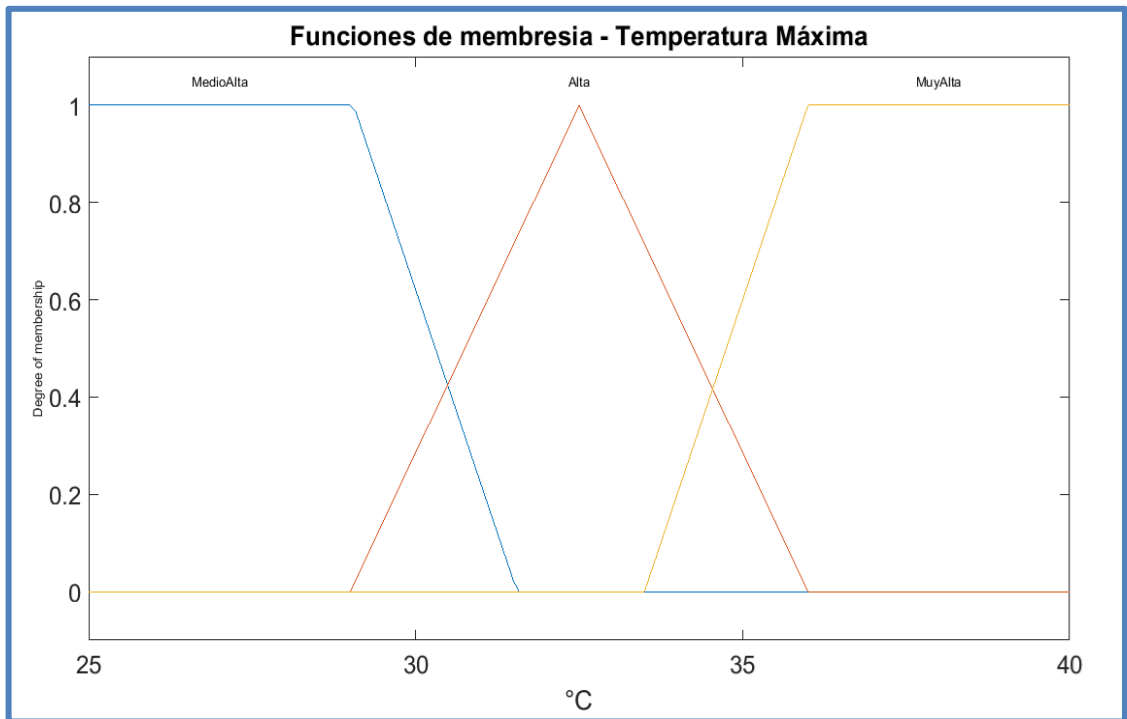


Figura 9. Funciones de membresía de temperatura máxima.




Figura 10. Funciones de membresía de temperatura mínima.




Figura 11. Funciones de membresía de humedad relativa.




Figura 12. Funciones de membresía de velocidad del viento.




Figura 13. Funciones de membresía de precipitación.




Figura 14. Funciones de membresía de radiación solar.




Figura 15. Resultados modelo Fuzzy.

Este modelo obtuvo un coeficiente de determinación de 0.42, o expresado de otra forma, se obtuvo que el modelo explica 42% de la variabilidad de la radiación solar, si se tiene en cuenta que el valor deseado de la bondad del ajuste es de 1, el resultado obtenido para este modelo no es muy alentador. Pero si comparamos el comportamiento de los datos estimados con los datos reales se puede identificar que tienen una tendencia, tratan de seguir los datos reales como se muestra en la Figura 15. Esto es bastante interesante ya que muestra que el modelo de predicción es preciso porque los datos estimados presentan un comportamiento similar a los datos reales de radiación solar a pesar de no obtener los valores exactos. Aunque esto muestra un buen resultado, no se debe tomar este modelo de predicción como el definitivo ya que cuenta con muchas variables de entrada además que tiene muchas reglas de inferencia, lo cual hace que el modelo pierda confianza porque el mejor modelo es el más simple y que muestra mejores resultados.

Se pudo sacar conclusiones útiles, como que las horas de brillo solar es una variable muy importante ya que se encontró en todas las reglas del modelo y en cuatro de esas reglas solo se utilizó esta variable de entrada y esto permitió mejorar el modelo. También se pudo identificar que las funciones de membresía son un factor relevante que pueden mejorar el modelo. Todos los conceptos descritos en este punto serán ampliamente detallados en el capítulo correspondiente al desarrollo del modelo de inferencia difuso. En el Anexo C se adjunta una tabla en la cual se relacionan las reglas del modelo descrito.

Capítulo 4. Modelo neuronal para predicción de radiación solar.

Las redes neuronales artificiales (RNA) son modelos matemáticos inspirados en el funcionamiento del cerebro. Las RNA son aproximadores no lineales que “imitan” el comportamiento de las redes neuronales biológicas. Permiten resolver problemas complejos, como sistemas no lineales, ya que tomando datos históricos de las variables de interés son capaces de aprender el comportamiento de esos datos y replicarlo de manera precisa incluso si se cambia el conjunto de datos dado inicialmente. Esto indica que las RNA pueden responder a situaciones a las cuales no han sido expuestas o que tengan información distorsionada porque generalizan a partir de casos anteriores.

Ya que las RNA son capaces de aprender de la experiencia con ejemplos ilustrativos se puede decir que son adaptativas. Para los sistemas neuronales, el procesamiento de la información es en paralelo debido a que varias unidades de procesamiento o neuronas pueden estar funcionando al mismo tiempo. Las neuronas están unidas entre sí por conexiones con pesos.

Un modelo neuronal básico cuenta con el conjunto de entrada, los pesos, la función de suma, la función de activación y la salida. Este modelo básico fue presentado por McCulloch W. y Pitts W. en 1943 [19]. El modelo neuronal mayormente utilizado es el perceptrón multicapa, el cual está organizado por capas. Cada capa está compuesta por un conjunto de neuronas donde las entradas de información vienen de la misma fuente y las salidas de información tienen el mismo destino. Para el perceptrón multicapa se cuenta con la capa de entrada, la capa oculta o intermedia y la capa de salida. La cantidad de capas de una RNA está definida por la cantidad de neuronas entre la capa oculta y la capa de salida. En la Figura 16 se representa el perceptrón multicapa.




Figura 16. Perceptrón multicapa.

En el proceso de aprendizaje las RNA actualizan los pesos e incluso su arquitectura, en algunos casos, para cumplir con el objetivo propuesto. Teniendo en cuenta la información de la que dispone la red se puede tener un aprendizaje supervisado donde se conoce la salida del problema y la red trata de disminuir el error existente entre la salida conocida y la calculada con el fin de que la salida calculada sea igual a la deseada, también se puede tener un aprendizaje no supervisado donde los valores de salida no se conocen y debe extraer rasgos

o agrupar información similar a partir de lo que conoce. Así mismo, en el proceso de aprendizaje se encuentra un concepto relevante denominado algoritmos de aprendizaje los cuales mediante un proceso matemático ajustan los pesos de la red y se tienen algoritmos como minimización del error, Boltzmann, Hebb y competitivo, donde se usan comúnmente los algoritmos asociados a la minimización de errores como el de retropropagación (backpropagation) [20].

El modelo propuesto en este capítulo utiliza dos tipos de redes neuronales muy interesantes y ampliamente empleadas en proyectos investigativos, las redes neuronales SOM (Mapas Autoorganizados) y las redes feed-forward backpropagation. Los mapas autoorganizados son modelos de aprendizaje no supervisado competitivo, por otro lado, las redes feed-forward son modelos que cuentan con aprendizaje supervisado. A continuación, se relacionan aspectos relevantes de ambos tipos de redes neuronales.

Mapas Auto-organizados (SOM)

Como se mencionó anteriormente son redes neuronales que poseen un aprendizaje no supervisado competitivo, lo que implica que no se conoce la salida del sistema (target) por lo que debe basarse en las entradas para cumplir con su objetivo. Las redes SOM deben identificar rasgos, similitudes, correlaciones o patrones en los datos de entrada y acoplarlos a su estructura interna de conexiones y pesos.

Se dice que es aprendizaje competitivo porque las neuronas compiten entre ellas con el fin de llevar a cabo una tarea dada. Cuando se presenta un patrón de entrada a la red, sólo una de las neuronas de salida (o un grupo de neuronas cercanas) debe activarse. Es decir, las neuronas compiten por activarse y solo queda una la cual se le llama vencedora, el resto de las neuronas no se tienen en cuenta y son forzadas a sus valores de respuesta mínimos. Las redes SOM crean categorías (clústeres) de los datos de entrada de la red, los valores similares se clasifican en la misma categoría y deben activar la misma neurona de salida [21].

Las redes SOM están compuestas por dos capas. La capa de entrada se encarga de recibir la información y transmitirla a la capa de salida. La capa de salida es la encargada de procesar la información y formar el mapa de rasgos. Es común encontrar que las neuronas de la capa de salida se organicen en forma de mapa bidimensional, esto se ve reflejado en la Figura 17.

Las neuronas de la capa de salida no están conectadas entre sí, pero cada una de éstas va a tener una influencia entre las neuronas cercanas a ellas, lo anterior se consigue a través de un proceso competitivo entre las neuronas, además de aplicar una función denominada función de vecindad, que produce la topología (estructura) del mapa. Es decir, las neuronas cercanas responden a patrones similares [22].




Figura 17. Estructura de las redes SOM.

Redes Neuronales Feed-forward Backpropagation

Las redes feed-forward son un conjunto de neuronas que reciben información de muchas variables, la procesan y luego dan una respuesta que puede ser multivariable también. La topología del arreglo de neuronas de las redes feed-forward y las conexiones entre ellas hace que la información fluya en una sola dirección para que no pueda pasar más de una ocasión por una neurona antes de que se genere la respuesta de salida [23]. Tal y como muestra la Figura 18.

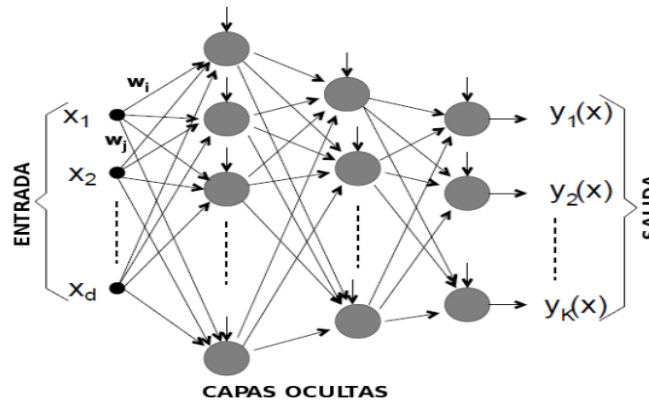


Figura 18. Diagrama de las redes neuronales feed-forward.

Las redes ingresan los datos a través de las neuronas de la capa de entrada, y al pasar la información a la capa oculta, las neuronas reciben la suma ponderada de las entradas que están conectadas a ella. Las conexiones entre neuronas representan un peso de conexión.

Como se mencionó anteriormente las redes feed-forward tiene un aprendizaje supervisado, el cual involucra un ajuste de los pesos comparando la salida deseada con la respuesta de la red de manera que el error sea mínimo.

El algoritmo de aprendizaje comúnmente utilizado en las redes feed-forward es propagación hacia atrás (backpropagation) el cual que busca reducir el error cuadrático medio (MSE) y es similar al método de regresión generalizado.

Después de tener claridad en las bases teóricas de las RNA se describe de manera detallada el desarrollo del modelo neuronal propuesto con la finalidad de predecir la radiación solar. En la Figura 19 se ilustran las etapas del desarrollo del modelo neuronal propuesto. Cabe recalcar que es diferente al modelo propuesto previamente y plasmado en el Capítulo 3.



Figura 19. Etapas de desarrollo del modelo neuronal de predicción de radiación solar.

4.1. Datos de entrada y salida para el modelo de predicción neuronal

Los datos utilizados en este modelo son los mismos que se usan en el modelo fuzzy descrito más adelante: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones. La salida del modelo será la radiación solar. El set de datos para el entrenamiento se tomó desde el 1 de febrero del 2013 hasta el 31 de diciembre del 2015, y para la simulación del modelo se tomó desde el 1 de enero de 2016 hasta el 30 de septiembre de 2016. Cabe aclarar que se definen 7 variables de entrada, pero se realizarán pruebas donde no necesariamente se usen todas las variables, esto con el fin de observar cómo es el comportamiento del modelo.

Aunque las variables de entrada de este modelo son las mismas del modelo fuzzy, se usan de manera distinta. El modelo neuronal es un modelo de aprendizaje y requiere de bastante precisión a la hora de escoger los insumos del sistema porque la inclusión o exclusión de una variable puede afectar el rendimiento del modelo. Esto se evidencia cuando el sistema no es capaz de aprender el comportamiento de los datos debido a la no relación entre las variables de entrada, eso impide la predicción. La forma en la cual se eligieron esas variables de entrada está descrita detalladamente en el Capítulo 3.

4.2. Diseño estructural del modelo de predicción neuronal

El modelo neuronal desarrollado en este capítulo tiene como función predecir la radiación solar diaria a partir de datos diarios de otras variables meteorológicas de fácil medición como las horas de brillo solar, nubosidad y temperatura. Para alcanzar el objetivo se utilizan las RNA, las cuales toman datos históricos de las variables meteorológicas y aprenden su comportamiento, así pues, son capaces de estimar los datos de radiación incluso con datos nuevos. Todo lo anterior ha sido explicado a lo largo del presente libro. La representación genérica de este modelo propuesto se muestra en la Figura 20.

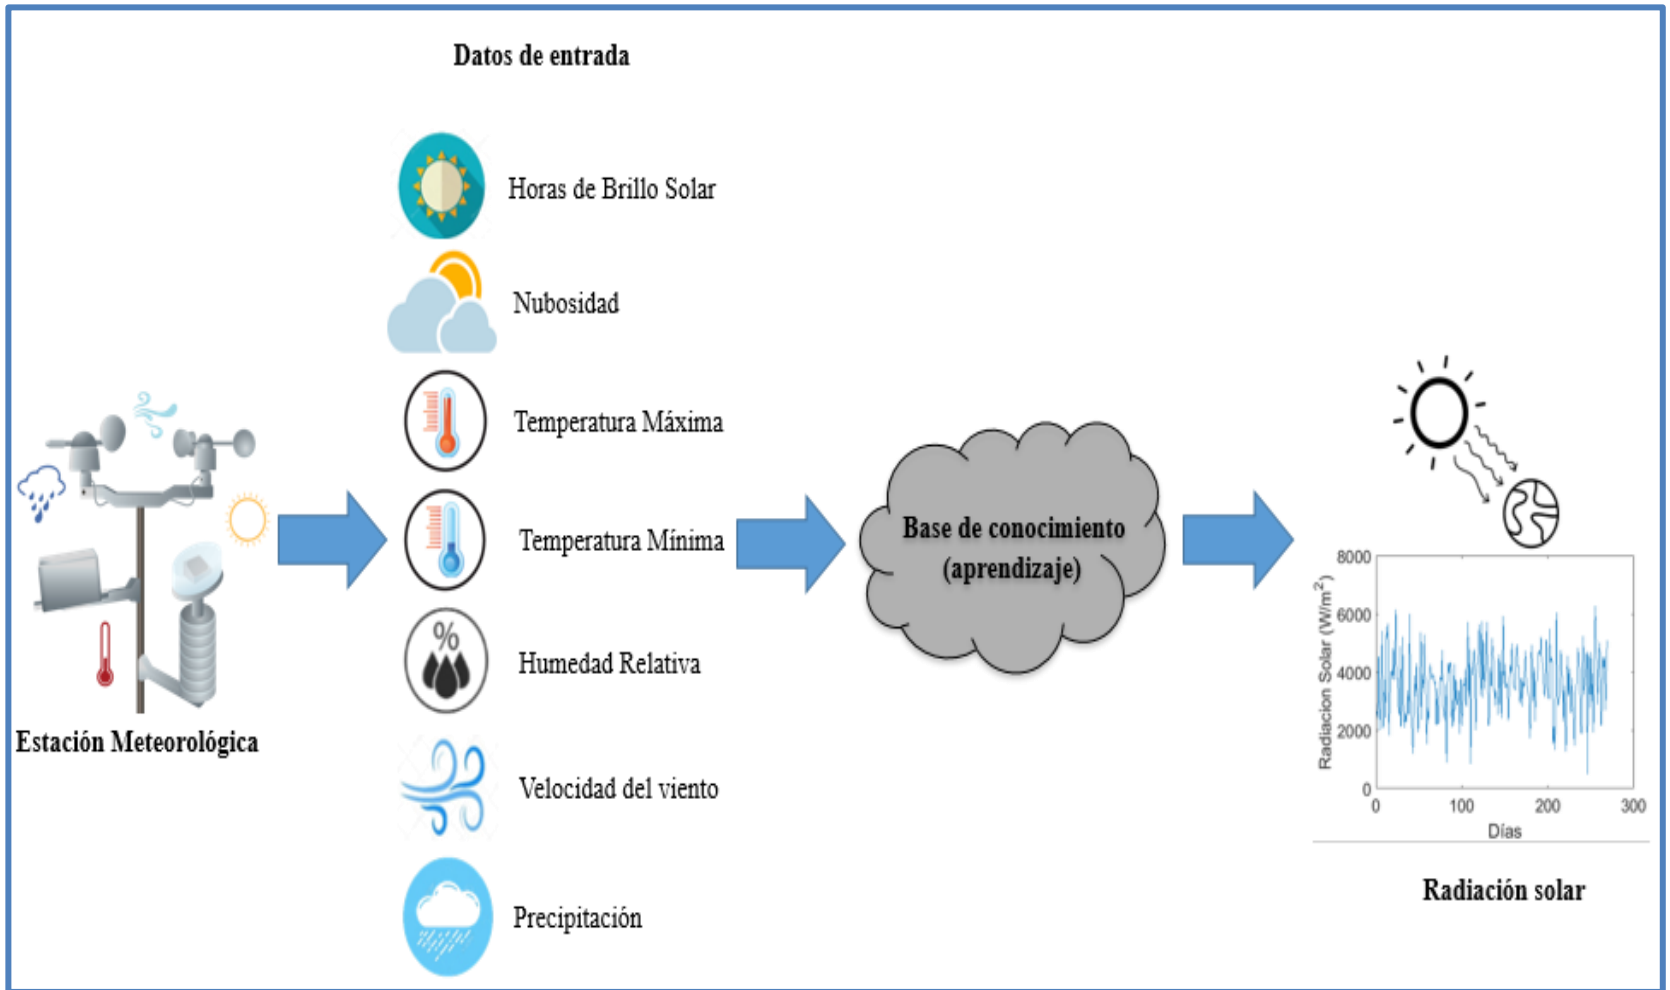


Figura 20. Representación genérica del modelo de predicción neuronal.

Con el fin de conseguir predicciones acertadas de la radiación solar se desarrolla un modelo que cuenta con dos tipos de redes neuronales muy útiles y pertinentes para esta clase de proyectos, que son las redes feed-forward y las redes SOM. Ambos tipos de redes neuronales fueron descritos en el inicio del presente capítulo.

Es fácil notar que el modelo neuronal propuesto es distinto al modelo neuronal previo mencionado en el Capítulo 3. El modelo previo utiliza las redes feed-forward y el suavizado de los datos para predecir la radiación solar, pero se pudo evidenciar que el suavizado de los datos es muy agresivo lo cual dificulta bastante el proceso de reversión del suavizado y los resultados obtenidos no están en escalas que puedan ser útiles. En cambio, el modelo neuronal propuesto busca clasificar los datos por categorías donde los valores sean similares con ayuda de las redes SOM, luego aplicar redes feed-forward a cada categoría y realizar la predicción a cada una para obtener al final una predicción completa del set de datos.

El desarrollo del modelo fue posible con ayuda del software Matlab usando Neural Network Toolbox, que ofrece funciones y herramientas para poder implementar el modelo diseñado. En la siguiente sección se especifican de manera detallada la construcción y entrenamiento del modelo basándose en las funciones de programación utilizadas en el proceso de elaboración.

4.3. Construcción y entrenamiento del modelo de predicción neuronal

Se plantea un modelo de aprendizaje supervisado, por lo tanto, se necesitan los datos históricos de radiación solar para el entrenamiento del modelo neuronal. Las series temporales de las variables de entrada y de salida deben ser los mismos. Tanto las variables a utilizar y las series temporales ya fueron definidas en este capítulo anteriormente. Una parte del modelo posee aprendizaje no supervisado, ya que se usa las redes SOM para la categorización de los datos. En la Figura 21 se presenta la estructura del modelo. Todo esto será explicado a medida que se desarrolle esta sección.

La construcción del modelo de predicción neuronal de radiación solar se describe siguiendo las funciones realizadas y los procesos que intervienen en el diseño y entrenamiento del modelo. Los procesos llevados a cabo son los siguientes:

- Procesamiento de la información.
- Categorización de los datos según la variable de entrada elegida.
- Implementación de una red neuronal para cada categoría.

Con respecto al procesamiento de la información, en el Capítulo 3 se realiza un pre procesamiento de los datos. Para este modelo se hacen uso de la normalización de datos e integración de datos como procesamiento adicional. La normalización solo se aplica a los datos de radiación solar, ya que la escala de estos datos es muy superior (en un factor de 1000) en comparación con los datos de las otras variables meteorológicas, por lo tanto, se toman los datos de radiación solar y se dividen por mil. La integración se aplica a todos los datos, tanto los datos

de entrada como los datos de salida. Para la integración se utiliza la función trapz de Matlab, la cual realiza la integración numérica mediante el método trapezoidal, este método aproxima la integración sobre un intervalo dividiendo el área bajo la curva en trapezoides con áreas más fácilmente comparables [24]. A la hora de aplicar el integrador al modelo se da la opción de ingresar el orden de integración deseado, así que el código desarrollado en Matlab es flexible en el sentido que permite integrar los datos si se quiere o dejarlo de orden cero donde no realiza la integración.

Para la categorización de los datos se plantea un código el cual permite elegir la variable que se quiere categorizar y con base en ella se categorizan las demás, por esta razón se define la topología de la red SOM como $1 \times C$, donde C es el número de neuronas o clústeres que van a “almacenar” los datos de esa variable con características similares. Debido a que los datos de la variable meteorológica no están ordenados según los clústeres, se debe tener un puntero el cual indique los días de los datos que pertenecen a cada clúster ya que es poco probable que datos consecutivos pertenezcan al mismo clúster; esto se hace con el fin de poder agrupar los datos de las demás variables con base en esos días específicos. Es decir, luego de categorizar la variable meteorológica de interés, se crea un vector puntero el cual indica a que día pertenece cada dato de cada clúster; posteriormente se definen esas categorías para esos mismos días de las otras variables meteorológicas; seguidamente se agrupan los de todas las variables según las categorías y se crean matrices de datos de entrada y de salida. Al final se obtienen C matrices de datos de entrada y de salida. La dimensión de las matrices de entrada es $m \times n$, donde m es el número variables definidas y n es el número de datos por cada categoría. La dimensión de las matrices de salida es $1 \times n$. Se puede observar fácilmente que la dimensión de las matrices de entrada y salida varía de acuerdo a cada categoría.

Se implementan redes neuronales feed-forward backpropagation con algoritmo de entrenamiento LM, dos capas ocultas y funciones de activación tansig para cada categoría. Se toman las matrices de entrada y salida por categoría, y se implementa la red neuronal para esos datos. Las matrices de entrada se tomarán como el patrón (P) y las matrices de salida se tomarán como el target (t). De cada red neuronal se obtienen matrices de dimensión $1 \times n$, esos vectores contienen los datos estimados de radiación por categoría. Esos datos obtenidos se encuentran en desorden, por la razón que se mencionó en el párrafo anterior. Para poder consolidar ordenadamente los datos estimados por cada red neuronal se debe tener en cuenta el vector puntero, definido previamente. El puntero tiene definido a que día pertenece cada dato de cada categoría, con base en ello se consolidan y se reordenan los datos estimados por cada red neuronal.




Figura 21. Estructura del modelo neuronal.

4.4. Modelo neuronal simple

Se propone otro modelo neuronal, muchos más simple, el cual utiliza solamente redes feed-forward y solo tiene una variable de entrada la cuál es horas de brillo solar. Este modelo se desarrolla con el fin de buscar el mejor modelo, que sea el más sencillo y que presente mejores resultados.

Este modelo neuronal tiene dos capas ocultas, se hace un barrido de neuronas modificando el número de neuronas por capa, se aumenta el número de neuronas de diez en diez y el máximo de neuronas por capa es de cien, de igual forma como se realizó en los modelos neuronales presentados en las secciones anteriores. Se prueba el modelo cinco veces para cada combinación, de esta forma se prueba la precisión y exactitud del modelo, es decir la repetibilidad y fidelidad de los resultados. El algoritmo de entrenamiento utilizado es el Levenberg–Marquardt.

Lo que diferencia este modelo neuronal es que solo se trabaja con una variable de entrada, la cual es horas de brillo solar; esto se debe a que es la variable más relevante teniendo en cuenta los cálculos del coeficiente de correlación de Pearson de cada variable, los resultados obtenidos por los métodos utilizados en el software WEKA, las gráficas de dispersión y los resultados obtenidos por el modelo difuso.

Para la representación genérica de este modelo neuronal se puede tomar la ilustrada en la Figura 20, pero difiere en el simple hecho de que solo se refleja como insumo horas de brillo solar.

Es fácil identificar que es un modelo mucho más simple que los modelos neuronales presentados anteriormente, debido a que solo utiliza una variable como entrada, la cual es la más relevante, este modelo promete resultados interesantes, los cuales serán mostrados en el Capítulo 6.

Capítulo 5. Modelo de inferencia difuso para predicción de radiación solar.

La lógica difusa representa de forma matemática información imprecisa, inexacta o con cierto grado de incertidumbre para el manejo de procesos, a diferencia de la lógica tradicional, la cual necesita información bien definida [25]. La lógica difusa permite relacionar entradas y salidas mediante condiciones de causa y efecto, esas condiciones son expresiones lingüísticas llamadas reglas de inferencia difusas y se representan por medio de juicios if-then [26]. Las reglas mencionadas son dadas por un experto que basado en el conocimiento que tiene del sistema o del proceso es capaz de definir estas reglas con precisión. Las reglas difusas se representan de la siguiente forma: IF antecedente THEN consecuente, donde el antecedente o premisa es (son) la(s) condición (es) que define (n) a las entradas del sistema y el consecuente es la acción a ejecutarse teniendo en cuenta esas condiciones establecidas [27].

Los sistemas difusos más populares son: Mamdani y Takagi-Sugeno. En la Figura 22 se presentan los diagramas del procesamiento de cada sistema difuso.




Figura 22. Diagrama del procesamiento general del sistema difuso: Mamdani (a) y Sugeno (b).

El tipo de sistema difuso más usado es el Mamdani ya que es fácil de aplicar y cuenta con defuzzificador que permite tomar la salida difusa y convertirla en salida numérica para que pueda ser interpretada por elementos externos como controladores.

Otro elemento importante de la lógica difusa son las funciones de membresía o funciones de pertenencia, ya que como su nombre lo indica, representan la pertenencia de un elemento a un subconjunto que está definido por una etiqueta; estas etiquetas se denominan universo de discurso, con el cual se definen las condiciones que se reflejan en las reglas de inferencia. Las funciones de membresía más utilizadas son: trapezoidales, triangulares y gaussianas.

Teniendo claras las bases de los sistemas difusos se describe el desarrollo del modelo planteado para predecir la radiación solar. La representación genérica del modelo fuzzy se muestra en la Figura 23.

5.1. Datos de entrada y salida

Para este modelo se toman como entrada las mismas variables meteorológicas utilizadas en el modelo neuronal: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones. La salida del modelo será la radiación solar, la cual se usó en los modelos anteriores.

La base de datos se tomará desde el 1 de enero de 2016 hasta el 30 de septiembre de 2016. Lo anterior se debe a que este mismo periodo de tiempo se tomó como conjunto de datos para la estimación de la radiación solar en el modelo neuronal, así que se debe utilizar la misma serie temporal para la predicción de radiación solar por medio del modelo difuso y al final poder realizar comparaciones precisas entre ambos modelos teniendo en cuenta que realizaron la predicción con la misma cantidad de datos.

Aunque las variables de entrada de este modelo son las mismas del modelo neuronal, se usan de manera distinta, ya que el modelo difuso está basado en decisiones que toma el experto y las expresa en forma de reglas en las cuales no necesariamente se deben incluir todas las variables de entrada porque la inclusión o no de cada una de estas variables puede afectar significativamente el rendimiento del modelo y esto es lo que define el experto apoyado en el conocimiento adquirido por la experiencia.

5.2. Funciones de membresía y universo de discurso

Como se mencionó anteriormente, las funciones de membresía representan el grado de pertenencia de los datos a un conjunto específico. Cada una de estas funciones tiene una ecuación característica, tienen una aplicación diferente y su elección depende de cuál sea la función que tome de una mejor manera los datos de la variable o variables a modelar.

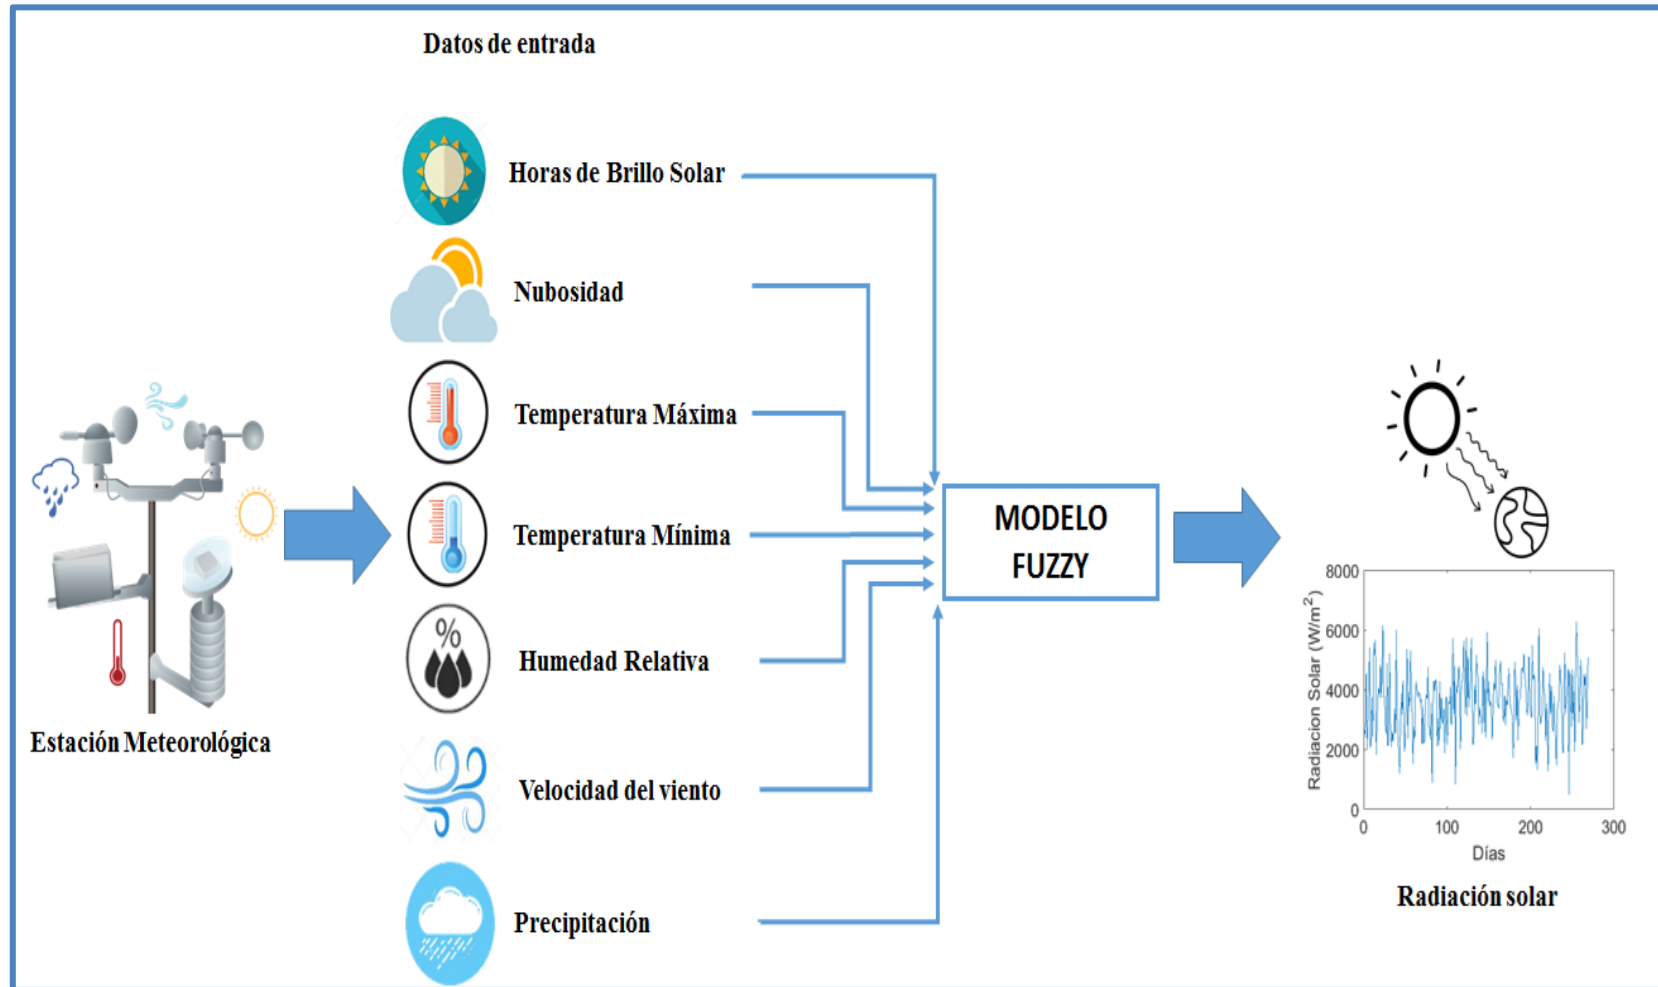


Figura 23. Representación genérica del modelo de predicción fuzzy.

La función de membresía escogida es la Gaussiana, se hace uso de esta función en cada una de las variables y para todo el universo de discurso. Esta función usa una distribución normal para convertir los valores originales y así definir el grado de pertinencia. El punto medio de la distribución normal determina el valor ideal en el conjunto; la pertenencia de los otros valores disminuye a medida que se alejan del punto medio, en ese caso se dice que dejan de pertenecer al conjunto. Esta función es útil si los datos se encuentran cerca de un valor específico [28].

Para encontrar el número y la distribución adecuada de las funciones de membresía se hace uso de Excel y se realizan gráficas para cada una de las variables en las cuales se relacionan el valor que toma cada variable y la frecuencia con la que aparece cada uno de estos valores. De la Figura 24 a la Figura 31 se muestra la distribución de los datos de cada variable meteorológica.




Figura 24. Distribución de datos de horas de brillo solar.




Figura 25. Distribución de datos de nubosidad.




Figura 26. Distribución de datos de temperatura máxima.




Figura 27. Distribución de datos de temperatura mínima.




Figura 28. Distribución de datos de humedad relativa.




Figura 29. Distribución de datos de velocidad del viento.




Figura 30. Distribución de datos de precipitaciones.




Figura 31. Distribución de datos de radiación solar.

Observando detalladamente las gráficas de la distribución de los datos de cada variable meteorológica, es posible determinar de manera aproximada el número de funciones de membresía para cada variable teniendo en cuenta la distribución de los datos que presentan las mismas. En la Tabla 6 se relacionan el número de funciones de membresía definidos para cada variable.

Para la implementación de este modelo se usó la herramienta Fuzzy Logic Designer del tool Fuzzy Logic de Matlab, la cual permite definir el tipo de sistema difuso, el número de variables de entrada y salida, el número y el tipo de funciones de membresía, el universo de discurso, entre otros.

Tabla 6. Número de funciones de membresía por variable.

Variabes Meteorológicas	Número de funciones de membresía
Horas de brillo solar	5
Nubosidad	6
Temperatura máxima	5
Temperatura mínima	5
Humedad relativa	5
Velocidad del viento	5
Precipitaciones	5
Radiación solar	5

Como se mencionó anteriormente, la función gaussiana fue definida como función de membresía para cada variable. Matlab ofrece dos tipos de función gaussiana; el primero es más conocido porque está representado por la clásica campana de Gauss cuyo punto medio está en el centro de la función, y el segundo es una combinación de dos funciones de membresía gaussianas que permite cambiar el punto medio. Para las variables de entrada las funciones de membresía fueron gaussianas tipo 1 y para la variable de salida fueron gaussianas tipo 2 debido a que los datos representados por cada función no tenían una distribución centrada en el punto medio.

Teniendo claro el número de funciones de membresía para cada variable se realiza la colocación de estas funciones teniendo en cuenta la distribución de los datos mostrada desde la Figura 32 hasta la Figura 39 y el rango definido por los valores mínimos y máximos de las variables tanto de entrada como de salida. Se considera también que las funciones de membresía deben estar superpuestas ya que según expertos y la literatura los niveles lingüísticos tienen límites grises los cuales pueden estar definidos en las intersecciones de las funciones [29].

El universo de discurso etiqueta cada función de membresía y con estas etiquetas se plantea las reglas del modelo de predicción. A continuación, se indica el universo de discurso para cada variable basándose en el número de funciones de membresía.

- Horas de brillo solar: Muy pocas, Pocas, Medio, Muchas, Demasiadas.
- Nubosidad: Muy baja, Baja, Medio baja, Media, Alta y Muy alta.
- Temperatura máxima: Muy baja, Baja, Media, Alta y Muy alta.
- Temperatura mínima: Muy baja, Baja, Media, Alta y Muy alta.
- Humedad relativa: Muy baja, Baja, Media, Alta y Muy alta.
- Velocidad del viento: Muy baja, Baja, Media, Alta y Muy alta.
- Precipitaciones: Muy baja, Baja, Media, Alta y Muy alta.
- Radiación solar: Muy baja, Baja, Media, Alta y Muy alta.

Con base en lo desarrollado en este capítulo, las figuras presentadas a continuación muestran las funciones de membresía ya implementadas para cada variable usando la herramienta Fuzzy Logic Designer del software Matlab.




Figura 32. Funciones de membresía de horas de brillo solar.




Figura 33. Funciones de membresía de nubosidad.




Figura 34. Funciones de membresía de temperatura máxima.




Figura 35. Funciones de membresía de temperatura mínima.

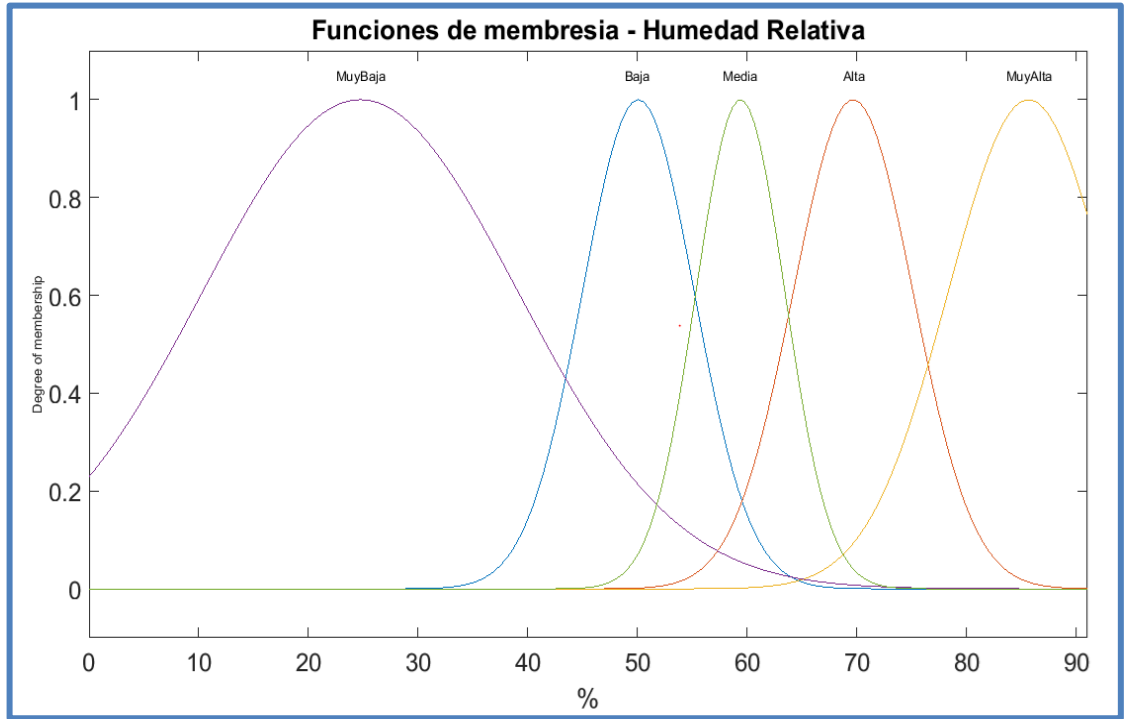


Figura 36. Funciones de membresía de humedad relativa.




Figura 37. Funciones de membresía de velocidad del viento.

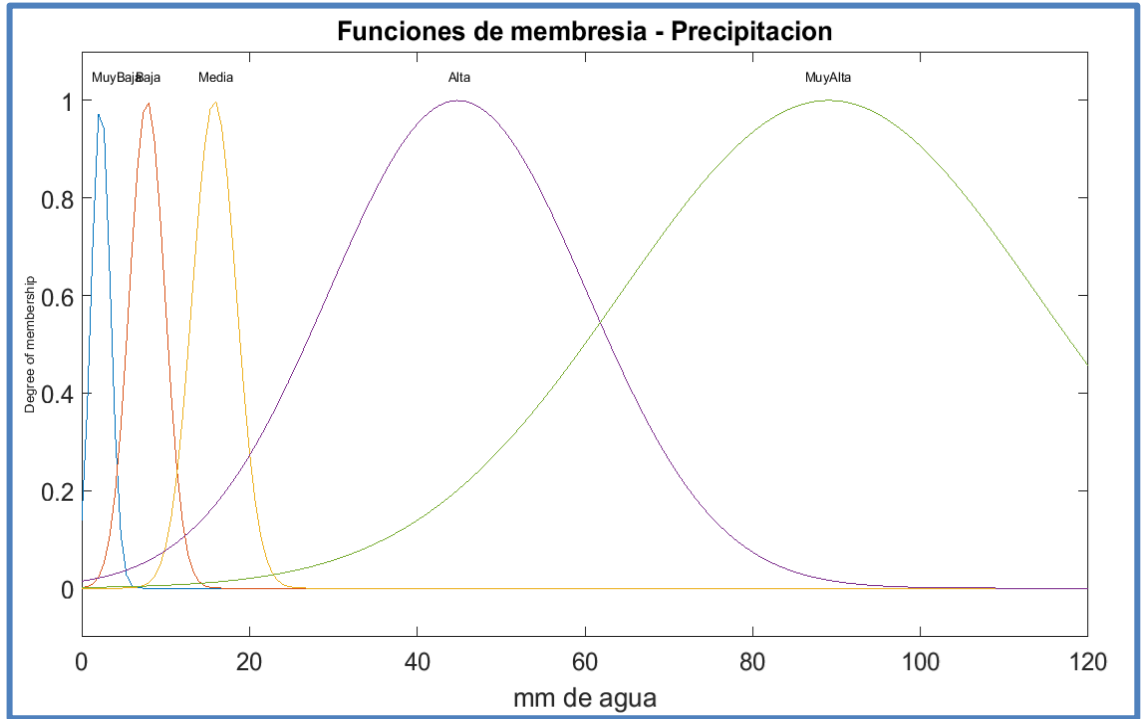


Figura 38. Funciones de membresía de precipitación.




Figura 39. Funciones de membresía de radiación solar.

5.3. Reglas de inferencia

Las reglas de inferencia son las expresiones que reflejan las condiciones del sistema difuso. Las reglas difusas se obtienen a partir de un conocimiento previo del fenómeno o variable de interés. Los resultados obtenidos del sistema difuso están relacionados con las reglas definidas ya que vinculan los datos de entrada y salida con premisas condicionadas, las cuales se deben cumplir para tener un resultado útil.

Debido a que el modelo propuesto posee diversas variables de entrada, será necesario utilizar varias de ellas en una misma regla, por lo tanto, se debe definir el conector lógico indicado que enlace de la mejor manera esas variables de entrada y así obtener los condicionales precisos para el modelo. En el modelo difuso propuesto se utiliza el conector lógico “and” para cada regla que necesite incluir varias entradas, este conector es incluyente por lo que se deben cumplir todas las condiciones expresadas en la regla para que se lleve a cabo.

Con respecto al número de reglas, se puede indicar que un sistema difuso con “n” entradas y “x” funciones de membresía para cada entrada, el número de reglas está definido de la forma x^n [30]. En este modelo se utilizaron 68 reglas, las cuales se definieron según la correlación entre variables mostrada en el Capítulo 3 y de manera heurística. Con respecto a las otras propiedades del sistema difuso como el método and y el método or se dejan por defecto (mínimo para and y máximo para or). Para la defuzzificación se utiliza el método del centroide. En el Anexo D se relacionan las reglas definidas para este modelo.

5.4. Modelo de inferencia difuso simple

Se propone otro modelo difuso, muchos más simple, se desarrolla con el fin de buscar el mejor modelo, que sea el más sencillo y que presente mejores resultados. Este modelo difuso cuenta con el mismo número de funciones de membresía y la misma distribución de esas funciones, utilizadas en el modelo descrito anteriormente (con 7 variables de entrada), para la variable de entrada y de salida. También se hace uso del mismo tipo de funciones de membresía, Gaussiana tipo 1 para horas de brillo solar y Gaussiana tipo 2 para radiación solar. Lo que diferencia este modelo de inferencia difuso es que solo se trabaja con una variable de entrada, la cual es horas de brillo solar; esto se debe a que es la variable más relevante teniendo en cuenta los cálculos del coeficiente de correlación de Pearson de cada variable, los resultados obtenidos por los métodos utilizados en el software WEKA, las gráficas de dispersión y los resultados obtenidos por el modelo difuso. En el Anexo E se relacionan las reglas definidas para este modelo. Para la representación genérica de este modelo difuso se puede tomar la ilustrada en la Figura 23, pero difiere en el simple hecho de que solo se refleja como insumo horas de brillo solar.

Es fácil identificar que es un modelo mucho más simple que el modelo difuso presentado anteriormente, debido a que solo utiliza una variable como entrada, la cual es la más relevante, este modelo promete resultados interesantes, los cuales serán mostrados en el Capítulo 6.

Capítulo 6. Resultados, conclusiones y trabajos futuros.

Para la predicción de la radiación solar se plantearon dos modelos basados en técnicas de inteligencia computacional, los cuales generan resultados de predicción que conllevan a conclusiones relevantes para el estado del arte. La culminación de este trabajo de tesis permite, además, proponer y motivar la realización de trabajos futuros para investigadores que deseen continuar con este apasionante tema.

6.1. Resultados obtenidos

Los modelos propuestos para predecir la radiación solar nacen como alternativas a las estimaciones presentadas por los sistemas estadísticos y matemáticos generalmente usados. En esta sección se plasman los resultados obtenidos para cada modelo, donde se relacionan los cálculos correspondientes para medición de rendimiento y eficiencia de los modelos.

En esta sección también se relacionan gráficas donde se muestran los datos estimados por cada modelo, además de realizar comparaciones entre el valor deseado y el valor obtenido por cada uno de los sistemas formulados.

6.1.1. Modelos neuronales

Para el modelo neuronal implementado con redes SOM y feed-forward se toman las variables horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitación como entradas y radiación solar como variable de salida. El proceso de selección de estas variables se explica en el Capítulo 3, además se aplica el preprocesamiento de eliminación de datos incompletos definido en ese mismo capítulo. El rendimiento de los modelos neuronales propuestos puede llegar a mejorar si se continúa investigando en trabajos futuros. Los resultados serán expuestos y revisados detalladamente a continuación.

Se define inicialmente la cantidad de neuronas para el mapa autoorganizado (SOM). Se toman diez neuronas, por lo tanto, es una red de 1x10. La variable que se define para categorizar es horas de brillo solar por ser una variable muy relevante. Con respecto a la(s) capa(s) oculta(s) de la red feed-forward, se decide que sean máximo dos capas ocultas; donde se hace un barrido de neuronas modificando el número de neuronas por capa, se aumenta el número de neuronas de diez en diez y el máximo de neuronas por capa es de cien. Se prueba el modelo cinco veces para cada combinación, de esta forma se prueba la precisión y exactitud del modelo, es decir la repetibilidad y fidelidad de los resultados.

Primero, se probó el modelo para las siete variables de entrada. Los resultados más relevantes se presentan en la Tabla 7. Se observa que los resultados muestran poca estimación de la radiación solar y el modelo que presenta el mejor rendimiento es el que posee diez neuronas en la primera capa oculta y diez neuronas en la segunda. El coeficiente de determinación (R^2)

para ese modelo presenta valores entre -4,661 y -0,3028. En teoría el R^2 no debe tomar valores negativos, pero posiblemente se presentan estos datos porque el modelo predice valores altamente negativos para varias observaciones a pesar de que todos los valores reales sean positivos, es un escenario muy poco probable pero la posibilidad existe [31], también es posible que esos resultados negativos se den porque los valores estimados sean muy bajos en comparación con los valores reales, esto se puede observar en la Ecuación 1. Con respecto al RMSE, se tomó ese modelo como el más preciso debido a la poca diferencia entre los valores máximo y mínimo, se puede evidenciar que los valores estimados tienen una precisión de $\pm 1499,5 \text{ W/m}^2$, aun así, es un valor alto ya que el valor RMSE deseado debe ser cercano a cero, esto no genera mucha confianza en el modelo.

Tabla 7. Resultados del modelo neuronal SOM y feed-forward con siete variables de entrada.

Capa Oculta		Capa de Entrada	Coeficiente de determinación (R^2)				Error de la raíz cuadrada de la media (RMSE)			
Número de neuronas		Núm. De entradas	Entrenamiento		Predicción		Entrenamiento		Predicción	
Capa 1	Capa 2	#	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.
10	0	7	-1,439	0,1995	-13,03	-0,8694	866,02	1496	1466,3	3600,1
60	0	7	-8,079	-2,009	-180,4	-6,0538	1662	2886	2848	14443
70	0	7	-4,872	-0,935	-107,9	-5,9646	1169	2345,5	1119,3	6763,7
10	10	7	-0,431	0,2447	-4,661	-0,3028	832,53	1146,1	1224,1	1499,5
20	10	7	-1,271	-0,157	-4,702	-0,6196	870,76	1443,6	1364,9	2554,2
30	10	7	-0,394	0,0392	-15,37	-1,5278	948,77	1131	1705,1	4386,6
80	10	7	-1,292	0,0592	-7,087	0,0409	929,21	1450,3	1050,3	3,049,7
20	30	7	-0,753	0,087	-6,729	-1,6124	924,91	1268,4	1733,4	2981,7
10	50	7	-0,732	-0,354	-26,75	-6,4859	1114,8	1260,7	2934,3	5650
30	60	7	-1,826	-1,267	-69,97	-12,004	1457,4	1610,2	3867,4	9034,7
60	60	7	-3,664	0,0425	-43,85	-13,789	937,33	2068,7	4124,3	7181,9
100	100	7	-0,748	0,1823	-20,995	-11,537	1266,3	1284,2	3797,4	5629,7

En la Figura 40, se muestra la comparación entre los datos estimados y los datos reales. Los datos estimados son los correspondientes al modelo neuronal de dos capas ocultas, con 10 neuronas en la primera capa y 10 en la segunda capa. Se determina que el modelo cumple con el objetivo propuesto, que es estimar la radiación solar, pero para algunos días aislados donde se evidencia que estima datos cercanos a los datos medidos. En ciertos días se ve que la gráfica de datos estimados trata de seguir la gráfica de datos reales, muestra una tendencia, pero no lo consigue en su totalidad. Realizando la prueba se ve que el modelo es capaz de entrenar a la perfección las redes feed-forward para algunas categorías, esto no muestra una predicción uniforme.




Figura 40. Predicción de radiación solar obtenida por el modelo neuronal SOM y feed-forward con siete variables de entrada, 10 y 10 neuronas en las capas ocultas.

En el modelo difuso de siete variables de entrada desarrollado en el Capítulo 5, se puede verificar que las variables horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima y velocidad del viento son las variables que mayor cantidad de veces se utilizaron en las reglas de inferencia. Esas variables meteorológicas mencionadas anteriormente se tienen en cuenta para realizar otra prueba del modelo. Se puede decir que son datos correlacionados y ofrecen una mejora en el rendimiento. En la Tabla 9 se muestran los resultados más destacados.

Se nota en la Tabla 8 que se obtiene un mejor rendimiento con 10 neuronas en la capa oculta, presenta mayor precisión en los resultados. Este modelo presenta valores de R^2 y RMSE ligeramente mejores a los presentados en la Tabla 7. Los resultados de R^2 también son negativos, -0.1428 en este caso, posiblemente por las razones mencionadas anteriormente, aunque se pueden llegar a mejorar. Presenta mejores resultados que el modelo neuronal con siete variables de entrada. La precisión del modelo de acuerdo al cálculo obtenido de RMSE es de $\pm 1188,8 \text{ W/m}^2$, es un mejor resultado si se compara con el modelo neuronal con siete variables de entrada, pero aún es un valor un poco alto que no genera mucha confianza en el modelo. En la Figura 41, se muestra la comparación entre los datos estimados y los medidos.

En la Figura 41 se muestra que los datos estimados por el modelo tratan de seguir la gráfica de datos reales de radiación solar pero no lo consigue en su totalidad. Logra estimar valores similares a los datos reales, además muestra una tendencia, donde en la mayoría de los casos si el valor de los datos reales baja el de los datos estimados también lo hace, lo mismo ocurre

cuando el comportamiento de los datos reales muestra un alza, los datos estimados también tratan de seguir este comportamiento. Se debe recalcar que no se obtienen los valores exactos, pero si valores similares. Este modelo es más confiable que el anterior ya que para analizar un modelo de predicción se debe enfocar en cómo es el comportamiento de los datos estimados en comparación a los datos reales. Aunque los resultados obtenidos por los métodos de validación calculados no son alentadores, al revisar gráficamente el comportamiento de los datos, este modelo genera un poco de confianza.

Tabla 8. Resultados del modelo neuronal SOM y feed-forward con cinco variables de entrada.

Capa Oculta		Capa de Entrada	Coeficiente de determinación (R ²)				Error de la raíz cuadrada de la media (RMSE)			
Número de neuronas		Núm. De entradas	Entrenamiento		Predicción		Entrenamiento		Predicción	
Capa 1	Capa 2	#	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.
10	0	5	0,075	0,1696	-2,0898	-0.1428	882,05	921,574	1146,5	1188,8
60	0	5	-6,384	-1,55	-34,177	-12,749	1529,7	2630,7	3976,6	6360,8
70	0	5	-5,404	0,154	-32,75	-7,1981	1271,4	2424,1	3070,7	6230,4
10	10	5	-1,198	0,1501	-24,231	-1,1411	883,09	1435,2	15693	5386,9
20	10	5	-0,371	0,1661	-5,558	-0,7846	883,91	1518,9	1432,7	2746,4
30	10	5	-1,571	0,2255	-2,9012	-0,2931	843,01	1535,9	1219,5	2118,2
80	10	5	-1,667	0,9097	-9,6726	-3,362	426,86	1564,3	1405,3	3503,6
20	30	5	-0,85	-0,0971	-15,943	-2,0667	901,89	1303,1	1878,1	4414,4
10	50	5	-3,921	-0,1059	-34,182	-6,196	1007,4	2125	2876,9	6361,2
30	60	5	-0,796	0,535	-46,71	-5,2868	968,42	1283,8	2689	7407,7
60	60	5	-0,152	-0,0888	-15,697	-5,9682	999,55	1038,8	2831	4382,3
100	100	5	-1,561	-0,3214	-76,066	-52,387	1112,7	1532,9	7836	9414,8

En la Tabla 9, se muestran los resultados obtenidos del modelo neuronal con redes feed-forward y una variable de entrada. Los mejores resultados y más precisos se presentan para el modelo que cuenta con 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa oculta. Este modelo presenta un valor máximo de R² de 0,1836. A comparación de los modelos anteriores este es un valor positivo, pero es menor al valor deseado (cercano a 1). Este resultado quiere decir que el modelo de predicción presenta un 18,36% de la variabilidad de la radiación solar respecto a su promedio es explicada por horas de brillo solar, lo cual no es un mal resultado teniendo en cuenta que no se usó ningún método para suavizar los datos, solamente se eliminaron los datos incompletos, que no pudieron ser medidos.

Con respecto al RMSE de este modelo, se obtiene una precisión de $\pm 984,921$ W/m². Este es un valor muy bueno comparado con los dos modelos neuronales mostrados anteriormente, genera mucha confianza y es mucho más sencillo ya que solamente se utilizan 2 capas ocultas

de redes neuronales feed-forward y una sola variable de entrada. Al comparar los datos estimados con los datos reales (Figura 42), el comportamiento de los datos estimados se asemeja mucho al comportamiento de los datos reales, los valores que se obtienen no son exactos, pero si son muy similares, lo que permite comprobar que este modelo neuronal es mejor que los otros dos modelos neuronales, los cuales utilizan más variables de entrada y dos tipos de redes neuronales (feed-forward y SOM).

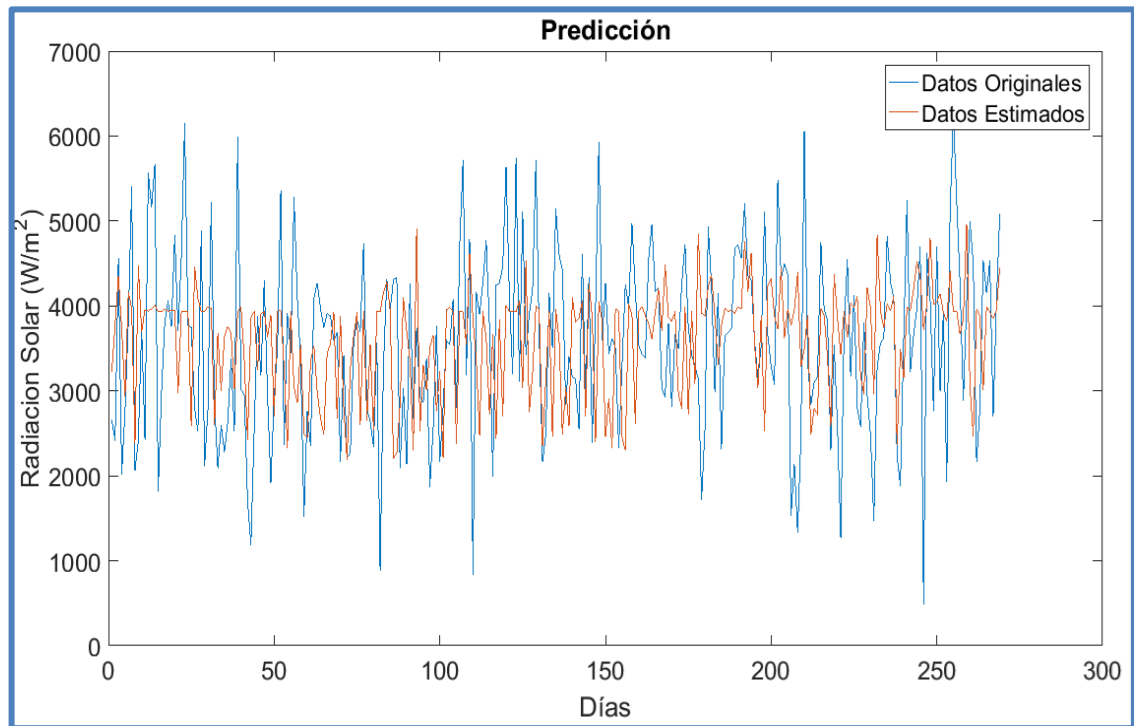


Figura 41. Predicción de radiación solar obtenida por el modelo neuronal SOM y feed-forward con cinco variables de entrada, 10 neuronas en la capa oculta.

Tabla 9. Resultados del modelo neuronal feed-forward con una variable de entrada.

Capa Oculta		Capa de Entrada	Coeficiente de determinación (R ²)				Error de la raíz cuadrada de la media (RMSE)			
Número de neuronas		Núm. De entradas	Entrenamiento		Predicción		Entrenamiento		Predicción	
Capa 1	Capa 2	#	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.
20	0	1	0,259	0,292	0,1352	0,2094	1032,4	1056	953,6	997,733
20	10	1	0,282	0,297	0,1566	0,1836	1028,5	1039,4	950,67	984,921
50	10	1	0,273	0,304	0,1247	0,1647	1023,1	1045,7	980,17	1003,4
10	20	1	0,257	0,299	0,1823	0,212	1027,4	1057,6	952,02	1019,5
30	20	1	0,308	0,315	0,1154	0,2	1015,1	1020,4	959,22	1008,7
60	20	1	0,287	0,326	0,0897	0,2346	1007,2	1035,9	938,27	1023,2
40	50	1	0,277	0,322	0,0022	0,2064	1010,4	1011,7	955,39	1071,3

30	70	1	0,312	0,322	0,1551	0,2058	1010,3	1017,4	955,72	985,758
20	80	1	0,295	0,303	0,1093	0,2157	1024	1030,4	949,77	1012,2
40	90	1	0,329	0,333	0,1022	0,1554	1001,9	1005,1	985,61	1016,2
50	100	1	0,326	0,328	-0,14	0,1218	1005,9	1007,2	1005	1145,2




Figura 42. Predicción de radiación solar obtenida por el modelo neuronal feed-forward con una variable de entrada, 20 y 10 neuronas en las capas ocultas.

6.1.2. Modelos difusos

Para el primer modelo difuso se toma como entrada el mismo conjunto de datos utilizado para predicción en el modelo neuronal, aplicando el preprocesamiento de eliminación de datos incompletos y sin suavizar, tal y como se explica en el Capítulo 5. Este modelo cuenta con las siete variables de entrada y la variable de salida documentadas en el Capítulo 3; cada variable tiene cinco funciones de membresía gaussianas excepto nubosidad que cuenta con seis, además el modelo posee 68 reglas de inferencia difusa, de más de 78125 reglas que permitía el modelo tomando como referencia la relación descrita en el Capítulo 5.

No se realizó un suavizado de datos de entrada ni normalización ya que el método propuesto pretendía predecir los datos obtenidos directamente por medición, a diferencia del modelo neuronal. Los rangos de las funciones de membresía se ajustaban a las escalas de datos de cada variable y al definir las funciones con las etiquetas del universo de discurso era más sencillo implementar las reglas de inferencia.

Se obtiene un valor de R^2 de 0.583, lo cual representa un 58.3% de la variabilidad de la radiación solar respecto a su promedio es explicada por las siete variables de entrada. Con respecto al RMSE obtenido, el modelo fuzzy de siete variables de entrada presenta una precisión de $\pm 692,5294 \text{ W/m}^2$, esto indica que los datos predichos del modelo están cerca de los datos reales de radiación solar.

En la Figura 43 se plasma el comportamiento de los datos estimados en comparación con los datos reales. Se observa claramente que el comportamiento de los datos estimados es muy similar al de los datos reales, muestran tendencia. Aunque no se estiman los valores exactos de radiación solar, los datos predichos describen un comportamiento muy similar al comportamiento mostrado por los datos reales. Todo lo expuesto anteriormente muestra que el modelo es bueno, que presenta buenos resultados, mejores a los obtenidos por los modelos neuronales.




Figura 43. Predicción de radiación solar obtenida por el modelo fuzzy con siete variables de entrada.

A continuación, se presentan los resultados obtenidos por el segundo modelo difuso, el cual contaba con horas de brillo solar como entrada con cinco funciones de membresía Gaussianas tipo 1 y 5 reglas de inferencia difusa. Para este modelo difuso tampoco se realizó un suavizado de datos de entrada ni normalización ya que el método propuesto pretendía predecir los datos obtenidos directamente por medición, a diferencia del modelo neuronal. Los rangos de las funciones de membresía se ajustaban a las escalas de datos de cada variable y al definir las funciones con las etiquetas del universo de discurso era más sencillo implementar las reglas de inferencia.

Se obtiene un valor de R^2 de 0.26, lo cual representa un 26% de la variabilidad de la radiación solar respecto a su promedio es explicada por horas de brillo solar. Con respecto al RMSE obtenido, el modelo fuzzy de siete variables de entrada presenta una precisión de $\pm 922,552$ W/m^2 , esto indica que los datos predichos del modelo están algo cerca de los datos reales de radiación solar. Estos resultados son buenos y presentan un modelo confiable, pero se debe mencionar que a pesar de que este modelo es más sencillo que el modelo difuso descrito anteriormente, no obtiene mejores resultados.

En la Figura 44 se evidencia el comportamiento de los datos estimados en comparación con los datos reales. Se observa claramente que el comportamiento de los datos estimados es muy similar al de los datos observados, claramente muestran tendencia. Aunque no se estiman los valores exactos, los datos predichos describen un comportamiento muy similar al comportamiento mostrado por los datos reales. Al igual como se expresó en el párrafo anterior, el modelo es bueno y presenta buenos resultados, mejores a los obtenidos por los modelos neuronales, pero no superan los resultados obtenidos por el primer modelo difuso.




Figura 44. Predicción de radiación solar obtenida por el modelo fuzzy con una variable de entrada.

No se puede realizar una comparación directa de los modelos propuestos en este documento (Modelos neuronales y modelos difusos) con los modelos planteados en otros trabajos ya que para realizar la confrontación estos deben estar en las mismas condiciones, que la ciudad objeto de estudio sea la misma y se tomen los datos de las mismas estaciones meteorológicas. Si se realizan comparaciones con los modelos encontrados en el estado del arte estas solo serían de tipo ilustrativo y no se tendrían conclusiones precisas ya que no hay verdades

absolutas con respecto al pronóstico de datos y todas las propuestas son válidas en el sentido en que se usen métodos confiables y consigan resultados relevantes. Por lo descrito anteriormente solo se harán comparaciones directas entre los dos modelos desarrollados en este trabajo.

Si se hace una comparación directa entre los modelos difusos y los modelos neuronales consignados en este documento, se puede afirmar con certeza que el modelo difuso con siete variables de entrada es mejor ya que el comportamiento de los valores de radiación estimados es muy similar al comportamiento de los datos reales de radiación solar. Se puede afirmar que el modelo difuso con siete variables en entrada estima datos de radiación inferiores a esos picos, esto quiere decir que el modelo difuso “peca por defecto”; para algunas aplicaciones es bastante útil ya que para ciertos días es posible que se puedan obtener valores de radiación un poco mayores a los estimados y puede generar mayores ganancias a las esperadas, por así decirlo, además el comportamiento similar a los datos reales permite hacer estimaciones del comportamiento y tomar acciones teniendo en cuenta esa tendencia. Los otros modelos propuestos solo pueden estimar algunos valores cercanos a los valores reales, para otros días es capaz de estimar valores de radiación solar mayores a los reales y el comportamiento de los datos estimados no es del todo fiel con respecto al comportamiento de los datos reales de radiación solar, lo cual no es útil en muchas aplicaciones porque si se obtienen valores de radiación menores a los esperados puede generar pérdidas; esto reduce el nivel de confiabilidad de los modelos.

Como se mencionó anteriormente los modelos neuronales y el modelo difuso con una variable de entrada ofrecen grandes aportes al estado del arte aún sin obtener resultados tan destacados y del todo confiables. Se debe recalcar el hecho de que los modelos difusos presentaron mejores resultados que los modelos neuronales. Todos los procesos desarrollados y los resultados obtenidos sirven como base para las investigaciones futuras. El modelo difuso con siete variables de entrada presenta un mejor rendimiento, permite llegar a conclusiones relevantes que pueden llegar a incrementar el interés en el pronóstico de datos meteorológicos. Las conclusiones y deducciones alcanzadas serán expuestas en la siguiente sección.

6.2. Conclusiones

Se implementaron los modelos propuestos de predicción de radiación solar, tres modelos usando redes neuronales artificiales y dos empleando lógica difusa. Con estos modelos se pretende aumentar el interés por la estimación de datos meteorológicos mediante técnicas basadas en principios de inteligencia artificial que permitan el pronóstico de datos cuya medición sea costosa y compleja; además de surgir como una alternativa a los modelos clásicos.

La idea fundamental de este proyecto es predecir la radiación solar en la ciudad de Neiva a partir de otras variables meteorológicas de fácil medición. Los datos fueron facilitados por IDEAM y provienen de estaciones meteorológicas reguladas y certificadas. Al hacer la revisión de los datos se tomó la decisión de utilizar los datos que provienen de la estación

meteorológica del Aeropuerto Benito Salas, excepto los de radiación solar ya que esta estación no cuenta con datos actualizados. Para los datos de radiación solar se tomaron los medidos por la estación La Plata, que está un poco alejada de la ciudad de Neiva, pero fueron los únicos datos de radiación solar ofrecidos por IDEAM que se encuentran actualizados, validados y calibrados, por lo tanto, estos datos son certificados y confiables. Se aplica un preprocesamiento el cual elimina los datos incompletos; este método toma los días que presentan una radiación solar menor de 10, luego busca esos mismos días en las series temporales de todas las variables meteorológicas y los elimina.

Dos modelos neuronales se implementaron usando redes SOM y feed-forward. Los modelos cuentan en primer lugar con aprendizaje no supervisado (red SOM) y en segundo lugar con aprendizaje supervisado (red feed-forward). La red SOM es de 1X10 neuronas, lo que permite obtener 10 categorías; y la variable que se toma para categorizar es horas de brillo solar. La red feed-forward cuenta con 2 capas ocultas y algoritmo de entrenamiento LM; se hace un barrido del número de neuronas de las capas ocultas, el cual se aumenta de diez en diez hasta llegar a cien en cada capa, este proceso permite identificar con que combinación se obtiene un mejor resultado. Se realizan pruebas de los modelos neuronales cinco veces para cada combinación para identificar la precisión y exactitud del modelo. Se puede decir que cada modelo neuronal cuenta con dos submodelos, el primero cuenta con las siete variables de entrada definidas en el Capítulo 3 y el segundo cuenta con cinco variables las cuales se toman a partir del modelo difuso de siete variables de entrada, expuesto en el Capítulo 5; se toman las cinco variables que mayor cantidad de veces se utilizaron en las reglas de inferencia. Este proceso se hace para poder concluir si las variables utilizadas en el modelo influyen en el resultado.

El otro modelo neuronal es mucho más simple, cuenta con una sola variable de entrada (horas de brillo solar), además usa redes feed-forward, por lo tanto, cuenta con aprendizaje supervisado. La red feed-forward cuenta con 2 capas ocultas y algoritmo de entrenamiento LM; se hace un barrido del número de neuronas de las capas ocultas, el cual se aumenta de diez en diez hasta llegar a cien en cada capa, este proceso permite identificar con que combinación se obtiene un mejor resultado. Se realizan pruebas de los modelos neuronales cinco veces para cada combinación para identificar la precisión y exactitud del modelo, al igual que en los modelos neuronales que usan redes tipo SOM y feed-forward.

Como se detalla en la sección de análisis de resultados, los modelos neuronales que usan redes tipo SOM y feed-forward no generan mucha confianza ya que los resultados obtenidos para la validación (R^2 y RMSE) no son muy buenos, además el comportamiento de los valores estimados no es muy fiel al comportamiento de los datos reales. Estos modelos pueden llegar a estimar valores cercanos de radiación solar en algunos días, pero no son modelos del todo confiables. En cambio, el modelo neuronal más simple, que usa redes tipo feed-forward y horas de brillo solar como variable de entrada obtiene mejores resultados, además el comportamiento de los datos estimados muestra la tendencia de seguir a los datos reales, por lo tanto, se puede afirmar que el mejor modelo neuronal es el más simple. Esto permite concluir que para aplicaciones en las cuales los datos sean estocásticos, la correcta

definición de las variables de entrada aporta una mejoría en el funcionamiento del modelo, incluso mayor que si se modifican la cantidad de las neuronas de las capas ocultas.

Para los modelos difusos se diseñó un sistema de tipo Mamdani, con siete variables de entrada y una de salida para el primer modelo, y una sola variable de entrada para el segundo modelo. Cada variable cuenta con cinco funciones de membresía, excepto nubosidad la cual tiene seis funciones. Se definieron claramente los rangos de cada variable para poder distribuir las funciones de membresía de tal forma que quedaran superpuestas y así evitar incertidumbres. Se optó por funciones gaussianas tipo 1 para las entradas y gaussianas tipo 2 para la salida ya que los datos están acotados, además de que la sección de mayor relevancia puede ser determinada por un conjunto de datos y no un dato específico. La cantidad de funciones y la distribución de estas se pudo definir graficando la frecuencia de los datos de cada variable.

Fue una decisión muy acertada implementar las funciones de membresía basándose en las gráficas de frecuencia de cada variable, ya que con esas gráficas se pudo definir la distribución de las funciones y el número de estas para cada variable. Se debe mencionar que fue muy conveniente la escogencia de funciones gaussianas para definir las funciones de membresía de las variables de entrada y salida porque los datos se encuentran en los valores específicos o puntos medios de cada función gaussiana y son pocos los que se acercan a las cotas de menor relevancia lo que evitó el uso de más reglas; es importante mencionar que se interceptaron las funciones de membresía para obtener una mayor incertidumbre que permita mayor efecto de las reglas en la salida del sistema.

Mientras se desarrollaba el primer modelo difuso se pudo notar que horas de brillo solar es una variable necesaria para la predicción de radiación solar. Esto se evidencia en las reglas de inferencia, horas de brillo solar está presente en todas las reglas. Se realizaron pruebas en las cuales se adicionaban reglas sin tener en cuenta la variable horas de brillo solar pero no se obtenían resultados favorables, incluso algunas reglas reducían el rendimiento obtenido. Teniendo en cuenta lo anterior, se puede afirmar que la variable más relevante del modelo difuso para la predicción de radiación solar es horas de brillo. Por lo tanto, se implementó el segundo modelo difuso utilizando solo horas de brillo solar como variable de entrada.

Al revisar los resultados obtenidos por ambos modelos difusos y el comportamiento de los datos estimados de cada modelo, se puede afirmar que el modelo difuso que tiene siete variables de entrada muestra un mejor rendimiento. Esto no significa que el modelo difuso con una variable de entrada no sea bueno, porque presenta valores de R^2 y RMSE interesantes, además el comportamiento de los datos de radiación solar estimados tiende a seguir el comportamiento de los datos reales, aunque con valores menores, no tan cercanos a los reales como los que presenta el primer modelo difuso implementado

Si se comparan directamente los modelos neuronales y difusos, el modelo difuso de siete variables de entrada presenta mejores resultados. Este modelo difuso permite estimar datos muy cercanos a los datos medidos, además el comportamiento de los datos estimados muestra

tendencia, ya que refleja como siguen los patrones de comportamiento presentado por los datos reales de radiación solar.

Como se ha venido mencionando en el presente capítulo, todos los resultados obtenidos son relevantes e importantes aportes al estado del arte. Son modelos interesantes que se pueden seguir probando hasta conseguir los resultados esperados, la clave consiste en persistir. Todos los modelos pueden llegar a ser mucho más precisos. Como afirmaba Thomas Edison: “no son fracasos, son intentos”. Esta investigación debe continuar para obtener resultados mejores, además de seguir contribuyendo al desarrollo científico y promover el interés en la predicción de datos meteorológicos.

6.3. Trabajos futuros

Este proyecto busca sentar las bases para que en un futuro se pueda realizar la predicción de radiación solar en tiempo real, tomando datos de estaciones automáticas que se encuentren en el punto geográfico de interés. Para esto se necesita una gran inversión ya que se debe contar con estaciones meteorológicas portátiles que permitan su fácil instalación y captura de los datos que serán el insumo de los modelos de predicción. Esto sería de gran ayuda para estudios físicos, biológicos y energéticos. Con respecto al campo académico, se recomienda realizar una investigación más profunda de modelos más eficientes y novedosos para la predicción de variables meteorológicas. Igualmente se espera que este trabajo de grado sirva como base para esas futuras investigaciones y se logre aumentar el interés y la curiosidad científica en la región sobre el pronóstico de datos climatológicos.

Referencias.

[1] S. Sayago, M. Bocco, G. Ovando, E. Willington. Radiación solar horaria: modelos de estimación a partir de variables meteorológicas básicas

[2] Disponible en:
<https://es.wikipedia.org/wiki/Neiva>

[3] Disponible en:
<http://www.mincit.gov.co/loader.php?lServicio=Documentos&lFuncion=verPdf&id=58188&name=GuiaTuristicaHuila-ok.pdf&prefijo=file>

[4] Disponible en :
<http://imagenes.interlatin.com/sdi/2015/10/25/ddd79feb6dc242d796722c1ee8d90af0.pdf>

[5] Cámara de Comercio de Neiva, Impacto de la crisis petrolera en el Huila – 2015.

[6] Disponible en:
<http://www.ideam.gov.co/web/tiempo-y-clima/radiacion-solar>

[7] Disponible en:
<http://www.ideam.gov.co/documents/21021/21129/.../2a207e33-fe43-4aa3-930d-70ba60b10d57>

[8] G. Andrés. Modelo para la predicción de la radiación solar a partir de redes neuronales artificiales.

[9] G. Federico. Predicción espacio-temporal de la irradiancia solar global a corto plazo en España mediante geoestadística y redes neuronales artificiales

[10] Amit Kumar Yadav, Hasmat Malik, S.S. Chandel. Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models.

[11] Disponible en:
<http://www.manualvuelo.com/NAV/NAV72.html>

[12] A. Eric y S. Javier. Descripción de dos métodos de rellenado de datos ausentes en series de tiempo meteorológicas.

[13] C. David, G. Paulina, T. Lizbeth, B. Ana, N. César y M. Diana.
Relleno de series anuales de datos meteorológicos mediante métodos estadísticos en la zona costera e interandina del Ecuador, y cálculo de la precipitación media.

- [14] Disponible en:
<https://personal.us.es/vararey/adatos2/correlacion.pdf>
- [15] Disponible en:
https://es.wikipedia.org/wiki/Coeficiente_de_correlaci%C3%B3n_de_Pearson
- [16] Hall M. Correlation-based Feature Selection for Machine Learning
- [17] Kononenko I. Estimating attributes: Analysis and extensions of RELIEF
- [18] Disponible en:
http://diccionarioempresarial.wolterskluwer.es/Content/Documento.aspx?params=H4sIAA AAAAAEAMtMSbF1jTAAASMjM0sTtbLUouLM_DxbIwMDS0NDA1OQQGZapUt-ckhlQaptWmJOcSoAQ9XICzUAAAA=WKE#I3
- [19] Disponible en:
<http://www.cs.us.es/~fsancho/?e=72>
- [20] Disponible en:
<http://avellano.fis.usal.es/~lalonso/RNA/index.htm>
- [21] Disponible en:
<http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema5dm.pdf>
- [22] Loaiza C. y Quintero S. Desarrollo de un modelo para la determinación de la presión de inicio de precipitación de asfaltenos (onset) en yacimientos de petróleo.
- [23] Vásquez J. Red neuronal feedforward como estimador de patrones de corrientes en el interior del puerto de manzanillo sujeto a la acción de tsunamis
- [24] Disponible en:
<https://la.mathworks.com/help/matlab/ref/trapz.html#bua4lsr>
- [25] Disponible en:
http://catarina.udlap.mx/u_dl_a/tales/documentos/meie/revelo_a_s/capitulo4.pdf
- [26] M. Arnaldo y S. William.
Técnicas de Lógica Difusa en Ingeniería de Control
- [27] P. Ricardo
Diseño de un controlador inteligente para el sistema Ball and Beam
- [28] Disponible en:
<http://desktop.arcgis.com/es/arcmap/10.3/tools/spatial-analyst-toolbox/how-fuzzy-membership-works.htm>

[29] M. Pamela y C. Lesia. A fuzzy linguistic model for the prediction of carpal tunnel syndrome risks in an occupational environment.

[30] Disponible en:

<http://www.scielo.org.co/pdf/ring/n22/n22a13.pdf>

[31] Disponible en:

<http://sitiobigdata.com/2018/08/27/machine-learning-metricas-regresion-mse/#>

ANEXOS

Anexo A. Datos meteorológicos utilizados en el desarrollo del modelo de predicción

Convenciones:

Variable	Significado
HB	Horas de brillo solar
N	Nubosidad
Tmáx.	Temperatura máxima
Tmín.	Temperatura mínima
HR	Humedad relativa
VV	Velocidad del viento
P	Precipitación
RS	Radiación solar

AÑO	MES	DIA	HB	N	Tmáx	Tmín	HR	VV	P	RS
2013	2	1	7	7,3333	33,9	23,4	66	1,925	9,8	2163,793
2013	2	2	2,9	7,3333	31,6	22,8	77	0,65	8	3490,8251
2013	2	3	5,4	5,3333	32	22,7	76	0,8083	1	2998,1968
2013	2	4	2,7	8	31	22,6	78	1,0875	51,4	3314,0446
2013	2	5	3,5	8	30,5	21,5	79	0,9	0	1002,9346
2013	2	6	2,3	8	31,6	21,6	77	0,775	1	4485,5099
2013	2	7	7,2	5,3333	33,1	23,5	69	0,5042	15,9	4906,2474
2013	2	8	6,5	7,3333	30,9	21,6	77	1,7542	24,1	4417,1548
2013	2	9	0,3	8	27,9	21,8	85	2,0625	4,4	1778,4116
2013	2	10	3,3	8	29,7	21,4	80	0,7	4,7	2609,2798
2013	2	11	3,4	8	29	21,5	78	0,675	36,9	3220,9402
2013	2	12	0,1	8	27,3	21,7	88	0,4708	0,7	1152,6087
2013	2	13	3,1	8	29,9	21,7	81	0,425	0,1	2451,3559
2013	2	14	7,2	6,6667	32,2	22,2	72	0,7917	0	5397,6971
2013	2	15	7	4	32,9	21,9	69	0,6083	0	6141,3537
2013	2	16	4,4	7,3333	32	22	67	1,2708	0	3134,9071
2013	2	17	2,9	7,3333	29,9	23	85	1,2458	0,6	3381,2212
2013	2	18	2,6	6	29,3	22,8	76	0,7917	0	3065,3734
2013	2	19	7,9	6,6667	32,5	22,5	65	0,9625	0	4226,2319
2013	2	20	8,2	4,6667	32,3	22,1	66	1,0875	0,4	3905,6699
2013	2	21	4,6	8	31,7	22,2	67	1,2583	0,4	2223,8984

2013	2	22	5,9	4,6667	35,1	23,4	66	0,775	0	3933,9548
2013	2	23	5,8	7,3333	34,3	23,4	62	1,0708	1	3064,1949
2013	2	24	4,4	5,3333	31,3	23	71	1,3292	2,6	1977,5842
2013	2	25	8,3	5,3333	34,3	22,8	66	0,7875	0	3748,9246
2013	2	26	7,8	7,3333	34	23	64	1	0,8	5752,4366
2013	2	27	3,7	8	30,9	23,2	73	2,2375	0,2	1951,6564
2013	2	28	2,4	8	32	23,8	67	1,4208	0	2702,3842
2013	3	1	3,5	7,3333	32,9	24,2	64	0	0	2985,2329
2013	3	2	5,9	7,3333	33,2	24	64	0	0	3651,1061
2013	3	3	2,7	6,6667	30,5	23	73	0	0,2	2677,6349
2013	3	4	0,8	8	26,8	22,1	87	0	3,9	1158,5014
2013	3	5	5,1	7,3333	32,4	21,4	70	0	0,4	3164,3705
2013	3	6	7,6	6,6667	35	21,5	66	0	0	4377,0845
2013	3	7	5,8	7,3333	33,7	23,2	65	0	0	4729,4669
2013	3	8	5,5	7,3333	33	24,6	62	0	0,3	1566,275
2013	3	9	1,8	6,6667	31,8	24,5	66	0	0	1541,5257
2013	3	10	0,7	8	31,4	23,2	73	0	0,5	2820,2378
2013	3	11	9,9	3,3333	36,9	21,2	62	0	12,2	5821,9703
2013	3	12	4,9	7,3333	33	21,2	70	0	0	3885,6348
2013	3	13	6,6	6,6667	34,1	23	68	0	0,5	4947,4962
2013	3	14	4,8	7,3333	33,3	24,3	71	0	0	3179,6915
2013	3	15	0,5	6	27,1	23,8	79	0	0	3064,1949
2013	3	16	0,3	8	29,1	22,2	79	0	0	2288,7179
2013	3	17	0	7,3333	30,3	22,8	72	0	0	1843,2311
2013	3	18	6,6	7,3333	35,8	23,6	67	0	0,2	5638,1186
2013	3	19	5,9	7,3333	33,8	22,6	69	0	0	4143,7343
2013	3	20	5,5	7,3333	34,6	22,8	67	0	0	3871,4924
2013	3	21	1,1	8	29,2	23,9	83	0	9,8	2519,711
2013	3	22	0	8	27,8	23,2	84	0	0,3	1335,2818
2013	3	23	0,3	8	29,4	22	80	0	0	1702,9852
2013	3	24	10	2	34,4	21,8	68	0	0	4873,2484
2013	3	25	8,4	6	35,2	21,8	65	0	0,3	3734,7821
2013	3	26	5,2	4	34,3	23,1	67	0	0	4996,9947
2013	3	27	9,9	2	36,4	22,2	57	0	0	6091,8551
2013	3	28	0	7,3333	31,2	22	69	0	0	2180,2925
2013	3	29	5,2	6,6667	32,8	21,5	62	0	0	2781,3461
2013	3	30	3,3	7,3333	31,6	21,6	61	0	0	2808,4525
2013	3	31	4,8	8	35,5	22,4	59	0	0	2623,4222

2013	4	1	3,3	7,3333	33,9	23	59	0	0	2972,269
2013	4	2	0,8	7,3333	30,8	23,8	66	0	0	2760,1325
2013	4	3	9,2	7,3333	34,3	22,4	62	0	0	4669,3616
2013	4	4	5,7	8	34,6	22,6	60	0	0	4676,4328
2013	4	5	7,9	6,6667	37	22,2	55	0	0	3902,1343
2013	4	6	8,7	6,6667	35,3	24,2	62	0	0	3970,4894
2013	4	7	6,4	6,6667	34,7	24	63	0	0	2529,1393
2013	4	8	0,8	8	32,2	24,1	72	0	0	1334,1033
2013	4	9	6,3	7,3333	33,9	22	61	0	0	2410,1071
2013	4	10	3,9	7,3333	33,5	23,2	63	0	0	3035,91
2013	4	11	9,6	6,6667	35,6	22,6	58	0	0	4821,3928
2013	4	12	8	5,3333	36,3	22,6	59	0	0	2953,4125
2013	4	13	3,5	7,3333	35	24,4	61	0	0	1107,8243
2013	4	14	0	8	30,9	24,9	66	0	0,1	1641,7013
2013	4	15	4,4	8	34,5	24,2	59	0	0,1	2367,6798
2013	4	16	7,7	6	36,8	24,3	51	0	0	3639,3207
2013	4	17	6,3	8	37,2	25,1	49	0	0,4	4461,9392
2013	4	18	7,8	6,6667	36,7	24,4	56	0	8,7	3553,2875
2013	4	19	2,9	8	31,4	22,4	74	0	66,6	2788,4173
2013	4	20	6,3	7,3333	31,2	21,8	73	0	0	3992,8816
2013	4	21	6	6,6667	31,2	22	75	0	5,3	3344,6866
2013	4	22	5,5	7,3333	31,8	21,6	78	0	25,3	3493,1822
2013	4	23	6,7	8	34,1	21,8	73	0	0	3334,0797
2013	4	24	10,2	3,3333	35,7	22	48	0	0	5923,3244
2013	4	25	10,7	3,3333	34,9	20,6	56	0	0	6729,4434
2013	4	26	10,4	3,3333	35,3	21,5	48	0	0	6624,5536
2013	4	27	7,2	4,6667	34,1	22,5	60	0	0,3	5024,1011
2013	4	28	6	7,3333	33,2	23,4	71	0	9,1	3443,6836
2013	4	29	0,7	8	29,1	22,1	77	0	0,1	2794,31
2013	4	30	10	6,6667	36,1	22,2	57	0	0	4712,9674
2013	5	1	4	8	33	23,2	66	0	0	3503,789
2013	5	2	4,9	6,6667	32,2	23,6	75	0	14,2	3556,8231
2013	5	3	6,9	6	31,1	21,4	76	0	0,3	3285,7597
2013	5	4	4,5	6,6667	32,7	22,3	71	0	12,4	4128,4133
2013	5	5	0,7	8	28,9	22,2	82	0	1,1	1855,0164
2013	5	6	4,5	7,3333	31,2	22,5	76	0	89,7	4100,1285
2013	5	7	0	8	27,8	21,3	95	0	19,7	1504,9911
2013	5	8	7,2	5,3333	32,2	21,3	71	0	0	5253,9157

2013	5	9	1,3	7,3333	30,4	22,2	73	0	0	2372,394
2013	5	10	7	4	32,8	22	70	0	1,7	4143,7343
2013	5	11	5,7	7,3333	30	22,5	82	0	3,8	4239,1958
2013	5	12	7,8	6,6667	33,8	23,6	70	0	0	4769,5372
2013	5	13	2,6	7,3333	31,2	23,2	69	0	0	2744,8115
2013	5	14	6,8	7,3333	34	23,8	70	0	1	4641,0767
2013	5	15	1,8	8	30,8	23,2	75	0	0,1	2485,5335
2013	5	16	7	6	32,7	23,2	67	0	0,6	4054,1655
2013	5	17	3,4	7,3333	30,8	23,4	82	0	0,3	3312,8661
2013	5	18	8,3	5,3333	33,7	23,6	67	0	0,6	3054,7666
2013	5	19	0,1	7,3333	31,2	23,6	91	0	8,2	1461,3853
2013	5	20	5,1	7,3333	32,6	22	72	0	0,7	4215,625
2013	5	21	2,9	8	30	23,4	74	0	4,5	2816,7022
2013	5	22	4	7,3333	32,8	22,9	71	0	0	4017,6309
2013	5	23	3,2	8	30,3	23	76	0	40,6	3229,19
2013	5	24	3,9	7,3333	30,2	21,6	81	0	2,8	3004,0895
2013	5	25	8,9	6	33,1	22,8	71	0	4,2	4895,6406
2013	5	26	3,1	8	30,1	22,8	75	0	0,2	3183,2271
2013	5	27	6,5	6,6667	32,7	22,8	71	0	0,1	4506,7236
2013	5	28	2,2	7,3333	29,6	23	80	0	0	3080,6944
2013	5	29	4,3	6,6667	31,8	22,6	77	0	28,5	3850,2787
2013	5	30	6	7,3333	30,8	21,6	73	0	7,6	3667,6056
2013	5	31	4,1	7,3333	30,7	21,6	72	0	0	4542,0796
2013	6	1	7,3	7,3333	32,1	22,4	79	0,7833	1,3	3450,7549
2013	6	2	9,1	6,6667	33,3	21,4	69	0,3917	1,9	4731,824
2013	6	3	4,6	6,6667	32	21,8	74	0,6333	0	2998,1968
2013	6	4	7,3	8	31,3	22,6	59	1,8625	0	3750,1031
2013	6	5	8,6	6,6667	33,7	23,5	54	1,025	0	4329,9431
2013	6	6	0,4	7,3333	29,8	21,8	70	0,5083	0	2923,949
2013	6	7	5	7,3333	32,3	22	60	1,0083	0	3521,467
2013	6	8	2,4	8	31,5	23,6	57	1,6958	0	2441,9276
2013	6	9	10,8	2	33,8	23,8	57	1,8333	0	4280,4445
2013	6	10	3,7	8	32,6	23,4	56	1,4542	0	3911,5626
2013	6	11	7,7	6,6667	33,4	22,4	61	1,3042	3,2	3512,0388
2013	6	12	4,3	5,3333	31,4	22,2	74	0,8542	1,3	4840,2494
2013	6	13	8,2	8	33,5	22,3	60	1,0583	0	3889,1704
2013	6	14	5,4	7,3333	32	22,7	62	2,5417	0	3456,6475
2013	6	15	5,9	7,3333	34,1	23,4	58	1,1708	0	4386,5128

2013	6	16	7,9	4,6667	35	23,7	59	0,9125	0	4952,2103
2013	6	17	5,9	5,3333	33,3	22,6	57	0,9833	0	3733,6036
2013	6	18	6,3	7,3333	33,2	23	57	1,1958	0	2949,8768
2013	6	19	7,4	7,3333	34,8	24,4	47	1,1667	0,1	3864,4212
2013	6	20	5,2	6	34,2	23	59	0,9375	0	3996,4172
2013	6	21	10,3	6	35,9	22,4	54	0,5958	0	3932,7763
2013	6	22	6,7	6	35	22,7	56	0,5125	0	4034,1304
2013	6	23	8,7	8	35,1	23,2	60	1,0042	0	4372,3704
2013	6	24	7,3	8	35,3	23,5	53	0,8375	0	4794,2865
2013	6	25	7,3	6,6667	32,8	23	58	0,5833	0	4268,6592
2013	6	26	10,6	5,3333	36,3	23,1	53	0,5958	0	4888,5694
2013	6	27	10	5,3333	36,6	23,8	46	1,0708	1,9	5014,6728
2013	6	28	8,4	6	34,8	22,7	58	1,0167	0	4546,7938
2013	6	29	7,7	6	33,3	23,4	63	0,5667	0,4	4201,4826
2013	6	30	5,2	8	31,2	22	71	0,7042	1,3	3702,9617
2013	7	1	3,6	6,6667	33,1	22,2	70	0,625	0	3197,3695
2013	7	2	5,7	6	32,4	21,9	63	0,9208	0	4035,309
2013	7	3	8,9	6	34	22	51	0,5583	0	4148,4485
2013	7	4	7,8	5,3333	34,6	23,1	56	0,4333	0,3	5370,5908
2013	7	5	5,3	8	32,6	22,6	70	0,7458	0,9	2922,7705
2013	7	6	6,7	8	33,6	23,4	51	1,6458	0,2	4974,6025
2013	7	7	9,3	6,6667	35,3	22,7	53	0,625	0,4	3327,0085
2013	7	8	9,4	8	33,4	22,8	57	0,6708	0	3935,1334
2013	7	9	1	7,3333	30	23	67	0,8292	1	2681,1705
2013	7	10	1,9	7,3333	28,3	21,8	69	2,3292	0,1	2263,9686
2013	7	11	6,7	8	33,1	21,8	55	1,6583	0	4308,7294
2013	7	12	3,4	8	33	22,6	56	1,2083	0	3407,149
2013	7	13	7	7,3333	34,4	22,8	51	1,8917	0	5245,6659
2013	7	14	6,7	5,3333	35,3	23,6	48	0,9	0,2	4187,3402
2013	7	15	3,4	8	32,9	24,2	58	2,05	0,3	4208,5538
2013	7	16	4,6	6	31,6	22,6	65	2,2583	0	2663,4925
2013	7	17	3,7	8	33	22,7	56	2,7667	0	4100,1285
2013	7	18	2,8	8	33,2	23,2	54	1,7208	0	3546,2163
2013	7	19	0,9	8	31,3	23,2	57	0,6292	0	3032,3744
2013	7	20	3,4	8	32,5	23,4	54	0,6875	0	3000,5539
2013	7	21	5,5	7,3333	34,9	23	53	1,1625	0	3017,0534
2013	7	22	9,7	6,6667	37	23,3	45	0,9583	4,5	4867,3557
2013	7	23	7	7,3333	35,2	22	66	0,9292	0	3212,6905

2013	7	24	8,9	4,6667	35,8	21,6	44	0,975	0	4700,0035
2013	7	25	3,1	8	33,3	23,2	51	1,3375	0,4	2075,4028
2013	7	26	4	6,6667	33,9	23	45	3,5333	0	2865,0222
2013	7	27	7,6	7,3333	34	23,2	41	3,3958	0	4364,1206
2013	7	28	8,9	6	34,4	22,4	45	2,2333	0,4	4681,147
2013	7	29	7,7	6,6667	35,4	23,6	51	2,7125	0	3288,1168
2013	7	30	5,1	7,3333	33,3	23,9	49	3,3917	0	3652,2846
2013	7	31	3,9	6	34,6	24,3	45	1,3125	0	3727,7109
2013	8	1	7,5	6,6667	35,2	23,5	50	0	2,7	4869,7128
2013	8	2	4	7,3333	34,9	23,4	55	0	0	4568,0074
2013	8	3	6,3	6	35	24	51	0	0	3885,6348
2013	8	4	3	7,3333	32,3	22,6	57	0	0	2889,7715
2013	8	5	7,9	4,6667	35,8	22,7	46	0	0	5638,1186
2013	8	6	10,4	6	37	23,6	42	0	0	5390,6259
2013	8	7	7,6	7,3333	35,8	24,6	60	0	0	3285,7597
2013	8	8	2,2	7,3333	32,7	24,2	61	0	0,4	3962,2397
2013	8	9	6,7	6	34,4	23,3	61	0	0	4010,5597
2013	8	10	6	8	31,5	23	70	0	8,9	3810,2085
2013	8	11	0,9	8	29,3	22,8	68	0	0,1	2192,0779
2013	8	12	7,8	6	34,4	22,8	59	0	0	4823,7499
2013	8	13	4,3	8	31,7	23,2	65	0	7,4	3344,6866
2013	8	14	4,6	7,3333	31,5	22,4	67	0	3,1	3487,2895
2013	8	15	4,8	7,3333	31,2	22,2	60	0	0	3242,1539
2013	8	16	5,4	7,3333	34,6	23,8	50	0	0	4658,7548
2013	8	17	3,9	8	33,4	23,8	49	0	0	3308,1519
2013	8	18	5,2	8	34,8	23,3	49	0	0	4036,4875
2013	8	19	4,6	8	34,4	23,4	45	0	0	5783,0786
2013	8	20	4,1	8	32,2	24,3	48	0	0	2928,6632
2013	8	21	5,1	6,6667	34,2	24,6	51	0	0	3832,6007
2013	8	22	7,3	7,3333	34,8	22,3	46	0	0	3305,7949
2013	8	23	3,7	8	34,9	22,2	53	0	0	4038,8446
2013	8	24	2,5	7,3333	32,1	22,5	60	0	0	3773,6739
2013	8	25	4,1	7,3333	33,4	23	63	0	0	3576,8583
2013	8	26	2,5	8	31,8	22	57	0	0	2774,2749
2013	8	27	5,8	6,6667	34	22,5	42	0	0	3140,7998
2013	8	28	1,6	8	31,4	24,8	53	0	0,4	4557,4006
2013	8	29	0,6	8	30,6	25	44	0	0	1640,5228
2013	8	30	5,1	8	35,1	24,5	39	0	0	4045,9158

2013	8	31	8,2	6,6667	36,1	24,4	39	0	0	4617,506
2013	9	1	8,7	7,3333	36	23,4	43	0	0	5812,542
2013	9	2	10	5,3333	36	22,4	46	0	0	6127,2112
2013	9	3	8,8	6,6667	34,4	23	54	0	0	4259,2309
2013	9	4	4	7,3333	34,3	23,3	63	0	1,9	2893,3071
2013	9	5	4,6	8	35,7	22,4	51	0	0	4457,225
2013	9	6	0,6	8	34,2	22,5	42	0	0	3726,5324
2013	9	7	6,4	7,3333	35,4	23,7	47	0	0,2	4870,8913
2013	9	8	3,8	7,3333	32,6	23,3	58	0	0	3361,1861
2013	9	9	4,5	8	34,5	22	59	0	0	3833,7792
2013	9	10	4	8	33,6	22	49	0	0	4215,625
2013	9	11	4,8	6,6667	35,8	24,4	42	0	0	4197,947
2013	9	12	8,2	6	34,8	23	51	0	0	4010,5597
2013	9	13	6,2	6,6667	34,9	23,3	62	0	2,2	3507,3246
2013	9	14	5	7,3333	34,2	24	56	0	0	3890,349
2013	9	15	1,9	7,3333	34,5	23,5	63	0	2,6	1488,4916
2013	9	16	8,5	8	35,5	22	50	0	0	3245,6895
2013	9	17	0,5	8	32,1	22,6	67	0	0	3263,3676
2013	9	18	5,1	8	33,9	21,9	66	0	1	3499,0748
2013	9	19	1,9	8	31,8	22	65	0	0	2093,0808
2013	9	20	3,8	5,3333	35,2	22,8	46	0	0	4679,9684
2013	9	21	10,6	3,3333	37,2	20,3	42	0	0	5991,6795
2013	9	22	4,5	7,3333	36,3	22,2	45	0	0	2980,5188
2013	9	23	6,8	6	36,6	24,3	39	0	0	3706,4973
2013	9	24	4	6,6667	34,6	26	50	0	0	2611,6369
2013	9	25	10,5	4,6667	35,8	25,4	42	0	0	4404,1909
2013	9	26	5,7	7,3333	36,7	25,4	38	0	0	4642,2552
2013	9	27	6,2	7,3333	36,6	26,6	50	0	3,7	4676,4328
2013	9	28	9,7	6,6667	36,4	24	46	0	0	5602,7625
2013	9	29	3,7	7,3333	32,6	23,4	74	0	5,7	3305,7949
2013	9	30	6,8	6	35,1	22,1	54	0	0	5496,6942
2013	10	1	4,4	7,3333	33,1	23,1	60	0	3,6	4987,5664
2013	10	2	7,4	6,6667	36,5	22,8	61	0	0	6220,3156
2013	10	3	4,7	8	32,7	23,2	56	0	0,1	3487,2895
2013	10	4	7,7	6,6667	35,1	23,8	51	0	0	2593,9588
2013	10	5	10,4	3,3333	36,7	22	50	0	0	5897,3966
2013	10	6	10,5	3,3333	37,7	22,7	41	0	0	5594,5127
2013	10	7	8,5	7,3333	35,6	23	47	0	0	4061,2368

2013	10	8	6,8	6	35,1	24,3	41	0	0	3169,0846
2013	10	9	7,1	7,3333	36,2	23,8	45	0	0	4360,585
2013	10	10	3,8	8	32,2	24,2	57	0	0,1	3303,4378
2013	10	11	6,3	8	33,3	23,6	67	0	1,5	4691,7538
2013	10	12	6,2	6,6667	34,2	23,9	62	0	0,1	4809,6074
2013	10	13	0,5	7,3333	30,3	24,1	69	0	2,3	2405,393
2013	10	14	2,2	8	30,3	23,6	81	0	2,1	2028,2613
2013	10	15	5,9	6	34,2	22,8	60	0	0	4213,268
2013	10	16	0	8	29,9	23,9	79	0	0,6	1382,4233
2013	10	17	1,2	8	31,6	22,5	63	0	0	3517,9314
2013	10	18	10,7	4,6667	36,6	21,1	50	0	0	6624,5536
2013	10	19	10,6	4,6667	37,3	22,3	50	0	0	5771,2932
2013	10	20	6,2	6	35,5	24,8	53	0	0,4	5730,0444
2013	10	21	4,3	7,3333	32,2	24,4	74	0	23,9	3420,1129
2013	10	22	6,4	6	30,8	21,3	77	0	0	5410,661
2013	10	23	6,7	7,3333	33,8	21,7	60	0	0	5052,3859
2013	10	24	6,6	5,3333	35,8	23,8	59	0	0	3866,7782
2013	10	25	6,6	6,6667	36,2	24	48	0	0	5225,6308
2013	10	26	10	6	36,6	23,3	45	0	2,8	4588,0426
2013	10	27	3	6	32,6	22	67	0	7,1	4271,0163
2013	10	28	9,1	6,6667	34,2	23,2	61	0	0,4	4362,9421
2013	10	29	7	6,6667	34,6	24,4	63	0	7	3608,6787
2013	10	30	2,6	8	29,9	24,4	82	0	14,8	2784,8817
2013	10	31	2,1	8	30,3	21,7	80	0	0,3	0
2013	11	1	4,8	7,3333	31,2	22,3	65	0	7,6	0
2013	11	2	7,2	6,6667	33,5	23	63	0	0,4	0
2013	11	3	4,1	7,3333	32,2	24,2	65	0	16,7	0
2013	11	4	1,2	8	27,2	22	86	0	15,8	0
2013	11	5	0,5	7,3333	27,2	21,6	83	0	0,5	0
2013	11	6	4,9	6	30,2	22,2	74	0	0,5	0
2013	11	7	6	6,6667	30,3	21,8	78	0	0,2	0
2013	11	8	3,4	8	30,5	21,8	76	0	46,2	0
2013	11	9	6,3	5,3333	30,3	21,2	79	0	17,1	0
2013	11	10	5,2	6,6667	30,6	21,3	77	0	1,1	0
2013	11	11	5,9	7,3333	32,6	21,4	71	0	0	0
2013	11	12	9	4,6667	34,1	23	62	0	0	0
2013	11	13	4	7,3333	32,7	24,1	65	0	0,7	0
2013	11	14	2,1	8	30,6	24,2	76	0	1	0

2013	11	15	6,5	5,3333	33,8	23	68	0	0	0
2013	11	16	9,7	4	34,5	23	65	0	0	0
2013	11	17	6,6	7,3333	32,2	23,8	65	0	0	0
2013	11	18	0	7,3333	29,3	24,2	82	0	0	0
2013	11	19	5,1	7,3333	31,4	23,8	71	0	3,8	0
2013	11	20	2,9	6	29,1	23,1	84	0	8,8	0
2013	11	21	4,2	6,6667	29,4	21	81	0	2,8	0
2013	11	22	5,1	6	29,7	21,2	79	0	6	0
2013	11	23	8,5	4,6667	31,3	22	72	0	17,1	0
2013	11	24	3,8	7,3333	30,3	22	80	0	2,9	0
2013	11	25	4,8	6,6667	30,2	22,2	79	0	0	0
2013	11	26	6,1	7,3333	30,8	22,4	71	0	33,3	0
2013	11	27	6,4	5,3333	30,3	21,9	78	0	3,1	0
2013	11	28	3,4	6	30,5	22,4	77	0	0	0
2013	11	29	3,9	5,3333	29,7	23,6	78	0	29,2	0
2013	11	30	2,7	7,3333	29,1	22	88	0	10,4	0
2013	12	1	2,3	7,3333	28,8	21,6	85	0	7,1	2870,9149
2013	12	2	4,3	7,3333	29,8	22	82	0	0,9	2418,3569
2013	12	3	3,1	5,3333	30	22,2	78	0	0	3866,7782
2013	12	4	4,7	5,3333	30,8	23,1	76	0	0,1	3172,6202
2013	12	5	6,2	7,3333	32,1	23,4	67	0	0	3065,3734
2013	12	6	6,8	6	33,5	22,4	70	0	0	5103,063
2013	12	7	5,6	6	28,8	22,6	76	0	1,9	2910,9851
2013	12	8	2,6	6	29,8	22	82	0	3,2	3435,4339
2013	12	9	1,9	6	29	22,1	82	0	2,5	3336,4368
2013	12	10	5	6	32,3	22,3	75	0	0	1989,3696
2013	12	11	4	6,6667	31,2	22,6	74	0	0,4	4136,6631
2013	12	12	5	5,3333	33	22,9	70	0	0	2655,2427
2013	12	13	5,9	6	33,3	23,1	71	0	0	3878,5636
2013	12	14	7,2	3,3333	33,4	23	67	0	0	2073,0457
2013	12	15	6,8	4,6667	33,1	22,8	66	0	0	5249,2015
2013	12	16	6,1	7,3333	32,1	23,1	66	0	17,3	4063,5938
2013	12	17	6	7,3333	32,6	22,4	75	0	19,2	3370,6144
2013	12	18	4,4	7,3333	30,4	22,8	78	0	0,1	3486,1109
2013	12	19	4,4	6,6667	31,8	23,4	74	0	1,7	3434,2553
2013	12	20	4,7	7,3333	30,5	23,9	73	0	0	1895,0867
2013	12	21	3,6	8	30,9	24,1	77	0	37,6	3272,7958
2013	12	22	2,7	7,3333	29,3	21,2	80	0	0	3244,511

2013	12	23	0,2	8	25,6	21,2	92	0	2,1	2886,2359
2013	12	24	7,5	5,3333	29,9	21,6	77	0	0	3423,6485
2013	12	25	6,2	7,3333	31,2	21,7	72	0	10,2	3187,9412
2013	12	26	5,1	6,6667	30,2	22,2	80	0	29,2	3688,8192
2013	12	27	3,2	5,3333	32,4	22,2	77	0	0	3061,8378
2013	12	28	8,8	3,3333	34,3	21,4	63	0	0	3033,5529
2013	12	29	8,8	4	34,4	21,4	63	0	0	5456,624
2013	12	30	8,9	3,3333	33,4	22,2	66	0	0	4506,7236
2013	12	31	8,6	3,3333	33,8	22,4	69	0	0,4	5421,2679
2014	1	1	7,5	6	34,2	23	69	0	0	5759,5078
2014	1	2	8,6	2	34,6	22,2	60	0	0	5677,0103
2014	1	3	6,1	6	33,5	22,3	67	0	0	5025,2796
2014	1	4	6	5,3333	33,8	23,5	64	0	0	4549,1509
2014	1	5	6	7,3333	35,3	23,2	61	0	0	4203,8397
2014	1	6	3,4	7,3333	33	23,2	68	0	16,3	2701,2056
2014	1	7	5,1	7,3333	30,8	22	81	0	7,3	0
2014	1	8	4,9	7,3333	29,3	21,8	81	0,1792	9,6	0
2014	1	9	0	7,3333	26,4	21,8	87	0,1208	8,8	2351,1803
2014	1	10	1,1	8	29,8	21,8	81	0	0,4	3508,5031
2014	1	11	5,8	8	31,4	22,5	76	0,1583	1,5	4074,2007
2014	1	12	7,4	6	32,4	21,7	66	0,0208	0	5649,9039
2014	1	13	8,5	2	34,3	21,3	58	0,3583	0	5292,8074
2014	1	14	7,1	4,6667	33,5	20,3	56	0,5458	0	3634,6065
2014	1	15	6,4	4,6667	34,5	20,5	63	0	0	5836,1127
2014	1	16	7,1	3,3333	33,8	22,6	63	0,2083	0	4367,6562
2014	1	17	6	4,6667	34,1	22,4	61	0,025	0	4341,7284
2014	1	18	2,2	8	32,8	22,7	69	0,7667	0	3166,7276
2014	1	19	2,9	6,6667	32	23,8	65	0,6	0	4063,5938
2014	1	20	8,1	6,6667	35	23,7	64	0,7542	0	5050,0289
2014	1	21	5,6	6	34,4	23,2	57	0,6875	0	4971,0669
2014	1	22	9,3	4	35	23,1	65	1,9167	0	5883,2542
2014	1	23	8,4	6	35,3	23,2	61	1,0375	0	4827,2855
2014	1	24	8	4	34,6	23,7	65	0,85	13,3	3878,5636
2014	1	25	6,9	6,6667	33,6	23,4	69	0,975	0,1	4408,905
2014	1	26	2,3	8	31,5	23,6	67	2,4167	1,1	0
2014	1	27	5,5	7,3333	33,3	22,8	68	0,75	0	0
2014	1	28	6,5	4	33,8	22,8	64	1,3708	0	5216,2025
2014	1	29	9,2	6	34,9	23,6	61	0,8667	8,3	4301,6582

2014	1	30	2,4	8	31,3	23,8	70	1,0542	13,6	3312,8661
2014	1	31	5,3	6,6667	32,2	22,6	71	0,4667	0	4509,0806
2014	2	1	9,1	6,6667	34,8	22,8	58	0,7125	0	6260,3859
2014	2	2	8,1	5,3333	34,8	23	60	0,625	0	4040,0231
2014	2	3	9,5	6,6667	34,5	23,5	64	1,3458	1,9	4562,1148
2014	2	4	3,9	6,6667	31,3	22,6	76	0,825	7,3	2758,9539
2014	2	5	3,4	8	31,6	22,5	76	1,3792	0	2688,2417
2014	2	6	2,1	8	30,9	22,5	73	0,3417	0	3365,9002
2014	2	7	8,6	5,3333	34,2	22,7	66	0,7833	0	3878,5636
2014	2	8	9,2	6	34,8	22,6	63	0,7792	0	3728,8895
2014	2	9	9,1	6	35,3	22,8	58	0,9583	0	4862,6416
2014	2	10	6,3	4	35,1	23,3	56	0,7042	0	4368,8348
2014	2	11	5,7	8	34,2	23,2	57	1,6875	0	4285,1587
2014	2	12	7,2	7,3333	33,7	22,8	57	1,0833	0	5164,3469
2014	2	13	6,7	6,6667	36	22,8	63	1,1667	18,6	3331,7227
2014	2	14	8,1	7,3333	33,3	21,8	67	1,0375	0,4	3843,2075
2014	2	15	9,5	6	34,8	22,3	63	0,7458	0	6345,2405
2014	2	16	9,5	6,6667	34,4	23,7	55	0,8	0	5202,0601
2014	2	17	8,4	6,6667	34,7	23,8	56	1,275	0	5312,8425
2014	2	18	5,8	5,3333	33,5	24,4	63	1,3542	0	4579,7928
2014	2	19	8,9	6,6667	34,6	22,6	62	1,3	0,2	3099,551
2014	2	20	4,6	6,6667	33	22,7	70	1,5833	0	3338,7939
2014	2	21	2,4	7,3333	31,8	23,8	72	1,675	0	4328,7645
2014	2	22	7,8	6,6667	35	22,5	65	1,0208	0,9	4259,2309
2014	2	23	6,4	7,3333	34,4	22,5	67	1,0042	1,1	5015,8513
2014	2	24	6,1	7,3333	34	23,6	69	0,9583	0,5	2815,5237
2014	2	25	1,2	7,3333	30,8	24,6	83	0,6667	33,6	1467,2779
2014	2	26	2,7	8	31,6	22,1	75	0,4708	0,1	2531,4964
2014	2	27	0,2	8	30	23,2	77	0,6708	0,8	1426,0292
2014	2	28	4,3	7,3333	31,7	22,4	68	0,65	3	2186,1852
2014	3	1	4	7,3333	29,7	22,7	82	0,8958	5,1	3248,0466
2014	3	2	5,4	6,6667	31,9	22	72	0,6417	0,6	3436,6124
2014	3	3	2,7	8	30,9	22,7	75	0,9083	13,3	2292,2535
2014	3	4	7,2	6,6667	32,4	21,5	71	0,9375	7	2177,9354
2014	3	5	2,1	8	30,8	21,5	75	0,8458	0	1573,3462
2014	3	6	7,1	4,6667	33,8	23,2	68	0,8042	54,4	4075,3792
2014	3	7	5,1	7,3333	32,5	22	74	0,6875	55	3836,1363
2014	3	8	3,6	7,3333	30,6	21,6	80	1,1958	0	4318,1577

2014	3	9	1,4	7,3333	31,1	21,8	72	1,4	18,1	2691,7774
2014	3	10	1,6	7,3333	31	22,4	77	0,6833	0,4	1912,7647
2014	3	11	5,1	7,3333	32,4	22,7	72	0,8	0,9	2656,4213
2014	3	12	2,6	7,3333	32,3	23,5	74	0,6083	3,2	3185,5841
2014	3	13	7	7,3333	32,2	22,5	72	1,6042	8,3	4283,9802
2014	3	14	5,3	7,3333	31,3	21	75	0,9542	7,9	1446,0643
2014	3	15	0	8	27,7	21,2	88	0,4958	16,7	2246,2906
2014	3	16	3	7,3333	30,7	22,7	76	0,4875	0	3933,9548
2014	3	17	7,2	6,6667	33,6	23,3	69	0,7125	0	3873,8495
2014	3	18	6,3	8	33,3	23,6	70	0,9667	0,4	3778,388
2014	3	19	3,6	7,3333	30,2	23,6	80	1,2583	5,7	1655,8438
2014	3	20	6,3	4	32,5	22,8	69	1,4125	0	3301,0807
2014	3	21	6,8	6,6667	34,1	22	65	0,775	0	4861,463
2014	3	22	3	8	32,1	22	71	2,1042	2,1	2235,6837
2014	3	23	0,2	8	29,3	22,2	81	0,3583	0	1553,3111
2014	3	24	3,8	7,3333	32,7	22,4	63	1,3333	0	2181,471
2014	3	25	4,6	8	33,4	23,4	73	0,7292	0	3038,2671
2014	3	26	3	8	31,1	23,7	78	1,1	0,4	2115,473
2014	3	27	4,1	7,3333	31,7	22,3	70	1,35	0	2322,8954
2014	3	28	7,4	7,3333	34,5	22	64	0,6708	0	4397,1197
2014	3	29	9,2	3,3333	35,3	22	63	0,7917	3,8	6533,8063
2014	3	30	6,8	8	34,2	23,5	65	1,6208	0	5962,2161
2014	3	31	8,5	4,6667	34,8	23,7	62	0,9458	0	5092,4562
2014	4	1	4,9	8	32,8	23,8	61	0,6875	0	2332,3237
2014	4	2	4,1	7,3333	32,5	23,8	62	0,9042	0	954,61456
2014	4	3	0,5	8	30,2	24	69	2,4958	0	1131,395
2014	4	4	7	5,3333	35,4	20,5	62	1,9583	0	2811,9881
2014	4	5	8,4	5,3333	34,8	21,2	56	2,1458	0	1013,5414
2014	4	6	8,6	8	35,7	23,8	51	2,5125	1,1	1316,4253
2014	4	7	3,7	7,3333	32,6	23	67	2,175	1,4	3159,6563
2014	4	8	3,8	7,3333	32,6	23,2	67	1,6	1,1	1309,354
2014	4	9	3,7	7,3333	32,1	23,7	65	1,4208	0,1	1612,2379
2014	4	10	8,7	6,6667	35	24,2	53	2,05	0	1461,3853
2014	4	11	5,4	6	34,8	24,5	54	1,9625	0	351,20388
2014	4	12	5,1	7,3333	33,9	22,9	58	1,35	0	2025,9042
2014	4	13	7,5	6	35,7	23,6	54	1,6208	0	3404,7919
2014	4	14	7,7	6,6667	35,9	24	54	3,0542	0	3971,668
2014	4	15	1,5	8	32,6	23,8	64	1,6167	0	2960,4837

2014	4	16	5,4	6	33,5	22,6	63	0,4042	1,8	3684,1051
2014	4	17	6,7	7,3333	33,2	22,6	68	1,0917	0	4606,8992
2014	4	18	9,5	6,6667	36,4	23	59	1,65	2,7	4636,3626
2014	4	19	7,1	8	34	22,8	64	1,6958	0,4	3430,7197
2014	4	20	5,1	5,3333	33,8	23	62	0,8792	0	3270,4388
2014	4	21	3,2	7,3333	33	23,8	56	1,0708	0	2321,7169
2014	4	22	2,4	8	31,7	24,3	65	0,8292	0	2677,6349
2014	4	23	10,3	6,6667	36,7	23,8	56	1,1042	22,6	4359,4065
2014	4	24	1,5	7,3333	31,3	22,4	0	0,1125	6,6	1812,5891
2014	4	25	6,7	5,3333	35,1	21,2	63	1,0958	0	5025,2796
2014	4	26	5,1	6	32,7	21,7	65	0,6708	0,1	3832,6007
2014	4	27	8,2	5,3333	34,1	23,6	62	0,9208	0	4240,3743
2014	4	28	8,8	7,3333	35,5	23,3	62	0,7292	9	4886,2123
2014	4	29	6,3	6	32,3	22,4	69	1,5167	0,1	4142,5558
2014	4	30	8,5	5,3333	34,8	23	64	0,9667	2,4	4545,6153
2014	5	1	8,5	6,6667	34,3	23	70	1,125	0,1	5589,7986
2014	5	2	5,3	7,3333	33,2	23,4	69	0,7125	10,2	4661,1118
2014	5	3	3,6	7,3333	33,2	23,4	70	0,7375	0	4480,7957
2014	5	4	6,2	6,6667	33,6	23,6	58	0,6042	0	4245,0884
2014	5	5	9,2	6,6667	35,6	24,8	58	0,7583	0	5735,9371
2014	5	6	5,9	5,3333	34,5	24,8	62	1,0208	14	3801,9587
2014	5	7	5,4	7,3333	30,8	22,6	80	0,8667	6,9	3497,8963
2014	5	8	4,6	8	31,4	22,5	76	0,75	19,9	3098,3724
2014	5	9	4,2	7,3333	29,8	21,8	82	0,5167	4,5	2968,7334
2014	5	10	4,3	8	30,5	22	83	0,4875	8,3	2652,8856
2014	5	11	3,1	8	28,8	22,9	84	0,3292	18,6	2786,0603
2014	5	12	7	6,6667	33,3	22,1	68	0,6958	0,3	3051,231
2014	5	13	10,6	6	34,3	23,8	66	0,4917	0	4866,1772
2014	5	14	2,6	7,3333	32,3	24,2	69	0,7167	0	2525,6037
2014	5	15	4,7	7,3333	32,9	23,3	65	0,8667	0	4113,0924
2014	5	16	7,3	4,6667	33	22,9	64	0,7667	0	4408,905
2014	5	17	2,9	6	29,7	23,7	79	0,6458	0,6	2859,1295
2014	5	18	2,1	6	30,8	23,4	82	0,4458	1,8	2182,6496
2014	5	19	1,1	7,3333	27,8	22,6	80	1,0833	2,7	2374,751
2014	5	20	9,1	6	35,5	22,5	66	0,7458	0	5689,9742
2014	5	21	6,7	7,3333	33,4	22,6	64	0,7208	12,8	4140,1987
2014	5	22	7,3	5,3333	32,6	21,5	72	0,9042	0	1275,1765
2014	5	23	8,8	4,6667	34,6	21,4	67	0,4375	1,8	3396,5422

2014	5	24	9,3	4	34,7	21,8	67	1,1	0	1798,4467
2014	5	25	8,1	6	34,2	21,6	61	0,7125	0	5087,742
2014	5	26	6,5	7,3333	33,5	22,2	64	1,2333	3,2	1751,3052
2014	5	27	1,9	8	31,5	22,6	71	0,8833	0	347,66827
2014	5	28	3,9	8	33,3	22,8	66	1,2375	0	4167,305
2014	5	29	5,9	8	33,6	23,6	65	0,4417	8	1964,6203
2014	5	30	7,1	8	32,1	22,2	65	0,5583	0	4584,507
2014	5	31	8,3	8	34,4	23,6	66	0,7708	0	4741,2523
2014	6	1	4,6	7,3333	34,2	24,2	65	0,8917	4	4493,7596
2014	6	2	4,7	8	31,8	22,7	69	1,1542	0	3821,9938
2014	6	3	5,9	6,6667	34,4	23	67	1,1167	6,8	1636,9872
2014	6	4	6,7	6,6667	31,7	22,9	73	1,3958	3	3296,3666
2014	6	5	7,7	4	34,8	22,3	64	1,0083	3,9	3147,871
2014	6	6	3,1	8	32	22,7	69	0,7458	0	2054,1891
2014	6	7	2,3	8	32,4	23,1	72	0,7875	0,4	1230,3921
2014	6	8	7	5,3333	33,6	22,8	69	0,6417	0	4384,1558
2014	6	9	6,4	5,3333	33,8	22,9	64	0,575	1	1207,9999
2014	6	10	3,1	8	32,2	22,7	75	0,7417	1	1778,4116
2014	6	11	9,7	4,6667	34,4	21	58	1,0625	0	2584,5305
2014	6	12	8,6	5,3333	34,8	21,8	56	1,3708	0,4	2161,4359
2014	6	13	5,5	7,3333	33,1	22,7	65	1,1333	0,5	3845,5646
2014	6	14	5,9	6,6667	34,5	23,4	66	1,575	2,6	1190,3219
2014	6	15	8,7	7,3333	35,4	23	54	1,825	0	3084,23
2014	6	16	6	7,3333	33,4	23,4	49	2,3375	0	1292,8545
2014	6	17	3,1	7,3333	32,1	25,4	50	2,8542	0	3865,5997
2014	6	18	0,3	8	31,3	25,1	57	4,3458	0	3301,0807
2014	6	19	2,8	8	32,1	25,2	46	4,9958	0	2844,9871
2014	6	20	2,2	8	31,3	23,5	46	4,6	0	2910,9851
2014	6	21	8,2	7,3333	34	21,1	47	2,2	0	5449,5527
2014	6	22	6,2	7,3333	33,6	22,9	52	2,0333	0	4723,5743
2014	6	23	6,7	6,6667	35,1	22	53	1,1917	0	3669,9626
2014	6	24	3,1	8	33	24	66	1,8	0,7	3357,6505
2014	6	25	0,1	8	29,7	22,4	78	0,4625	1,8	2562,1383
2014	6	26	7,9	5,3333	35,1	21,4	64	0,5875	0	4853,2133
2014	6	27	8,2	6,6667	35,2	21,8	52	0,3833	2,5	4999,3518
2014	6	28	4,8	8	33	22,3	64	0,925	0,4	2556,2457
2014	6	29	6,9	5,3333	35,8	22,7	53	1,0792	0	4100,1285
2014	6	30	5,4	8	32	22,7	59	2,3667	0,1	4103,6641

2014	7	1	8,8	6,6667	35,9	23,8	52	1,2458	0	5372,9479
2014	7	2	7,4	7,3333	32,8	24,2	61	2,3875	0	4549,1509
2014	7	3	9	5,3333	36,3	22,8	52	0,875	0	3824,3509
2014	7	4	1,5	8	34,2	23,2	57	0,675	0,1	3248,0466
2014	7	5	8,1	4,6667	36,1	23,1	55	0,775	0,1	4210,9109
2014	7	6	5	5,3333	34,2	23,1	56	0,7667	0	3252,7607
2014	7	7	7,9	7,3333	35,6	24,9	52	1,4875	2,4	4425,4045
2014	7	8	4,1	8	32,8	22	65	2,0917	0	3961,0612
2014	7	9	6,7	6	34,1	22,6	54	1,825	0	4438,3684
2014	7	10	2,1	8	33,1	24,3	57	2,6875	0	3335,2583
2014	7	11	2	8	31,3	23,8	58	2,6042	0	3786,6378
2014	7	12	4,8	6,6667	33,1	22,1	55	3,3167	0	4697,6465
2014	7	13	4,3	7,3333	33,8	22,3	56	3,3708	0,3	2939,27
2014	7	14	5,3	7,3333	36,3	24,6	56	1,9958	0	3140,7998
2014	7	15	6,3	8	34,1	23,6	59	2,775	0	2929,8417
2014	7	16	5,2	7,3333	33,7	24,7	51	1,6542	0	1389,4945
2014	7	17	4,3	7,3333	34,2	26,1	54	3,075	0	253,38535
2014	7	18	4	5,3333	34,4	25,6	54	2,1652	0	718,90726
2014	7	19	6,3	7,3333	33,8	25,5	51	1,6208	0	42,427314
2014	7	20	6,6	5,3333	35,7	24,1	53	2,0333	0	585,73264
2014	7	21	9	5,3333	35,3	24,5	52	2,2708	0	595,16093
2014	7	22	8,6	6	32,6	25	57	3,125	0	1381,2448
2014	7	23	7,4	5,3333	34,8	24,6	49	2,1958	0	335,8829
2014	7	24	9,7	3,3333	36,2	24,8	47	1,6792	0	1418,9579
2014	7	25	6,9	6,6667	34,7	24	52	1,3083	0	3045,3383
2014	7	26	5,5	7,3333	34,4	24,6	49	2,1792	0	3661,7129
2014	7	27	6	6,6667	34,8	25,4	42	1,45	0	3448,3978
2014	7	28	8,2	4,6667	35,6	24,6	45	1,5792	1,4	3593,3578
2014	7	29	6,6	6	34	22,1	52	2,2125	3,8	3422,47
2014	7	30	4,3	6,6667	31,7	22,2	57	2,1583	0	5321,0923
2014	7	31	6,3	5,3333	33,8	21,9	42	2,8667	0	3065,3734
2014	8	1	8,6	5,3333	37	24	39	2,4833	0,2	3497,8963
2014	8	2	1,3	8	31,2	24,5	49	2,2375	0	0
2014	8	3	0,6	8	32,2	20,1	54	1,5875	0	0
2014	8	4	10	6	35	21,6	46	1,0667	0	0
2014	8	5	0,8	8	32,5	22,6	54	1,5208	0,7	1998,7979
2014	8	6	5,8	8	31,7	23,2	57	2,5333	0,1	2088,3667
2014	8	7	4,1	7,3333	33,2	23,2	47	2,0958	0	2299,3247

2014	8	8	6,8	6,6667	34,7	24,1	47	1,8792	0	3710,0329
2014	8	9	9,1	4,6667	34,5	23,7	47	2,6958	0	0
2014	8	10	6,7	6,6667	34,8	24	45	2,1083	0	3581,5724
2014	8	11	5,9	5,3333	35,1	24,3	47	1,4708	0	3066,552
2014	8	12	3,1	6	34,3	24,4	57	1,4458	0	3046,5168
2014	8	13	5,4	6,6667	35	22,5	64	1,75	2,1	3937,4904
2014	8	14	5,6	6	34,3	21,2	54	1,25	0	3138,4427
2014	8	15	8,6	6,6667	33,8	21,3	48	2,7708	0	3157,2993
2014	8	16	3	8	33,6	25,1	47	2,1833	0	2751,8827
2014	8	17	2,8	7,3333	30,8	25,2	45	3,9875	0	4263,945
2014	8	18	2,7	8	32,4	25,1	48	2,9167	0	2295,7891
2014	8	19	0,4	8	30,4	24,3	46	2,3833	0	2354,7159
2014	8	20	6,5	6,6667	34,6	23,6	40	4,175	0	3661,7129
2014	8	21	5,3	8	34,3	23,8	36	3,1875	0	4684,6826
2014	8	22	8,2	5,3333	36,3	24,3	34	3,0958	0	6497,2717
2014	8	23	6	8	35,1	25	34	1,5375	0	4725,9313
2014	8	24	8,8	4	35,7	24,9	45	0,4917	0	4763,6445
2014	8	25	1,2	8	32,3	25,6	66	1,2792	1,3	3025,3032
2014	8	26	5,3	8	34,4	23,2	50	1,6542	0	3322,2944
2014	8	27	3,8	7,3333	33	23,4	50	0,9958	0	3966,9538
2014	8	28	5	8	33,1	23,5	50	2,1708	0	5171,4181
2014	8	29	4,3	8	33,7	23	50	1,9625	0	2936,9129
2014	8	30	9,5	6	37,2	23,1	38	1,6042	0	4800,1791
2014	8	31	10	5,3333	36,8	24	35	1,7042	0	4595,1138
2014	9	1	6,7	6	36,6	24,2	38	1,0208	0	4473,7245
2014	9	2	0,6	8	32,3	26	56	0,75	0	1534,4545
2014	9	3	8,1	6	35,2	23,1	49	1,1833	1,7	4135,4846
2014	9	4	9,7	6,6667	35,3	22,5	55	0,7417	0	3502,6105
2014	9	5	7,9	7,3333	36	22,4	46	1,4542	0	3319,9373
2014	9	6	5,8	6,6667	35,4	22,8	41	1,7667	0,1	2466,6769
2014	9	7	7,2	8	33,8	24	47	3,2875	0,3	1,1785365
2014	9	8	3,8	8	32,5	22,8	58	2,5208	0	1355,317
2014	9	9	9,3	2	37,1	22	46	1,8875	0	5705,2952
2014	9	10	1,5	7,3333	33,2	23,7	45	1,05	0	3279,8671
2014	9	11	8,6	7,3333	36,4	23,6	47	1,0625	1,1	5680,5459
2014	9	12	4,5	6	34,3	23,9	58	0,8625	0	2938,0915
2014	9	13	3,8	7,3333	35	24	50	0,9833	0	3546,2163
2014	9	14	4	7,3333	34,2	24,6	51	1,6458	0,1	3462,5402

2014	9	15	6,2	6	35,5	23,4	52	0,5833	0	4710,6104
2014	9	16	4,9	6,6667	36	23,4	53	1,2583	0,1	4253,3382
2014	9	17	6,1	6	36,7	24,4	44	0,6542	14,5	3521,467
2014	9	18	4,6	8	33	22,5	66	0,7292	12,9	4010,5597
2014	9	19	8,2	6	36	22,6	57	1,3542	0	5508,4796
2014	9	20	4	7,3333	31,8	23,3	67	1,2292	1	3209,1549
2014	9	21	4,8	6	34,1	23,3	58	1,0708	0	4570,3645
2014	9	22	5,7	7,3333	35,2	24,1	58	0,9833	1,6	4089,5216
2014	9	23	9,9	6	36,9	23,2	49	0,6208	0	3797,2446
2014	9	24	7,2	3,3333	36,4	23,9	56	0,5333	0	4665,826
2014	9	25	7,7	5,3333	37,8	23,1	48	0,525	0	6247,422
2014	9	26	10,2	2	37,6	23,2	41	0,8167	0	5957,502
2014	9	27	5,6	5,3333	34,7	24	52	0,9542	0	2978,1617
2014	9	28	6,1	6,6667	35,1	25,2	41	1,3125	0	2905,0925
2014	9	29	7,7	3,3333	36,6	24,2	37	1,2583	0	4193,2328
2014	9	30	7,3	5,3333	36,8	23,3	36	1,0083	0,4	5324,6279
2014	10	1	9,1	6,6667	36,7	23,6	37	1,3667	4	4892,105
2014	10	2	3,2	6,6667	33,1	21,4	61	0,65	0	1951,6564
2014	10	3	6,3	8	32,6	21,9	57	3,3333	0	3074,8017
2014	10	4	7,5	4,6667	36,2	23,4	41	1,3958	0	4731,824
2014	10	5	7,9	5,3333	38	24,8	45	0,9667	0	5116,0269
2014	10	6	4,3	7,3333	35,4	24,6	46	1,875	0	3341,151
2014	10	7	5,8	5,3333	36,4	25	43	0,6083	0,3	3996,4172
2014	10	8	3,9	6,6667	32,9	24,1	68	0,975	2,3	2399,5003
2014	10	9	4,8	6	29,8	22,4	79	0,8958	34	3984,6319
2014	10	10	3,2	5,3333	31,8	21,7	66	0,7292	0	3354,1149
2014	10	11	0,7	8	31,6	23,4	65	0,3042	0	3071,2661
2014	10	12	4,4	6	34,8	24	51	1,5875	0	4281,6231
2014	10	13	1,4	6	32,8	24,6	45	2,9167	0	3002,911
2014	10	14	3,4	7,3333	35	25	48	2,2042	0	3244,511
2014	10	15	1,2	7,3333	34	25	46	1,6792	0	2663,4925
2014	10	16	2,9	6	34,8	23,5	44	1,8875	0	4760,1089
2014	10	17	9	4,6667	36,4	24,5	41	1,1042	0	4762,466
2014	10	18	5,4	6,6667	35	25,1	50	0,4917	0,5	4418,3333
2014	10	19	5,8	8	33,2	24,2	68	0,7708	0	4308,7294
2014	10	20	2,7	7,3333	27,4	23,7	79	0,6958	4	2865,0222
2014	10	21	8,4	5,3333	35,3	22,3	52	0,325	0	4777,7869
2014	10	22	5,7	8	34	23	51	1,3	0	4187,3402

2014	10	23	6,7	4	37,4	23,3	49	0,475	0	4929,8182
2014	10	24	9,3	6,6667	35,6	23,8	50	0,85	78,9	3126,6573
2014	10	25	4,5	7,3333	32,8	21,2	74	1	32	5070,064
2014	10	26	0,3	7,3333	27,5	21,5	83	0,2917	5,9	2459,6057
2014	10	27	5,4	7,3333	32,7	21,8	69	0,7833	0	3842,029
2014	10	28	9,1	6,6667	33,6	23,5	63	0,5375	17,4	3844,386
2014	10	29	5,1	6	31,8	22,4	71	0,7125	20,9	2208,5774
2014	10	30	3,9	6	32,7	22,6	79	0,6625	21,5	4214,4465
2014	10	31	7,1	3,3333	32,5	21,9	69	0,1	28,6	3792,5304
2014	11	1	3,7	7,3333	30,3	22,3	75	0,3417	2,2	2063,6174
2014	11	2	4	7,3333	29	22,2	80	0,45	0,3	3230,3685
2014	11	3	7,6	4,6667	35,4	22,2	64	0,2625	0	5433,0532
2014	11	4	5,2	7,3333	32,6	22,9	65	0,4042	13,5	3103,0866
2014	11	5	2,3	6	29,9	22,2	89	0,3083	15,9	2967,5549
2014	11	6	5,6	7,3333	31,5	22,2	74	0,35	10,2	3060,6593
2014	11	7	7	6	32,5	22,1	74	0,6625	0	1876,2301
2014	11	8	8,2	5,3333	33	22,6	70	0,5125	0	5837,2913
2014	11	9	7,5	6,6667	33,2	23,4	70	0,6	16,1	6098,9264
2014	11	10	7,6	5,3333	32,3	21,7	74	0,35	4,8	3285,7597
2014	11	11	5	6	29,8	21,8	78	0,0542	1,7	4386,5128
2014	11	12	0,1	7,3333	27,2	22,1	89	0,0833	3,5	1363,5667
2014	11	13	6,2	7,3333	31,7	22,5	76	0,8667	0	3739,4963
2014	11	14	2,5	7,3333	30	23,8	70	0,8708	3,8	1680,593
2014	11	15	4	6	30,1	22	74	0,3458	2	2195,6135
2014	11	16	1,7	7,3333	28,7	22	78	0,1	0	2311,1101
2014	11	17	4,6	6,6667	33,9	22	62	0,4833	0	2976,9832
2014	11	18	10,1	3,3333	33,7	22,2	62	0,1542	7,9	4789,5723
2014	11	19	5,8	6,6667	30,7	22	75	0,3208	0,1	3096,0154
2014	11	20	5,5	5,3333	31,5	22,6	71	0,4	1,3	3739,4963
2014	11	21	2,8	8	30,5	23,6	72	0,5125	16,9	2334,6808
2014	11	22	4,6	5,3333	30,6	21,8	78	0,05	0,4	3515,5744
2014	11	23	6,2	5,3333	31,8	22,5	70	0,1458	0,3	4661,1118
2014	11	24	8,4	3,3333	33,3	23,1	64	0,2	0,5	6068,2844
2014	11	25	7	6,6667	32,4	23,4	71	0,6833	43	3225,6544
2014	11	26	3,9	8	31,5	23,3	77	0,9792	3,3	3048,8739
2014	11	27	7,3	5,3333	31,6	23	71	0,5833	0	3440,148
2014	11	28	8,7	6	33,8	23,2	65	0,1	0	6263,9215
2014	11	29	7,8	6,6667	34,4	23,6	66	0,3042	1	3059,4807

2014	11	30	4	7,3333	34,3	24,1	64	0,2583	0	2459,6057
2014	12	1	8,8	6	34,8	23,2	61	0,6042	0	4595,1138
2014	12	2	6,4	4,6667	34,5	23,5	59	1,275	0	4188,5187
2014	12	3	7,2	3,3333	35,5	22,8	57	0,9667	0	3813,7441
2014	12	4	2,8	5,3333	32,8	22,8	66	0,825	0	3752,4602
2014	12	5	8,2	6,6667	34	23,8	63	0,6708	70	4892,105
2014	12	6	5,7	6,6667	30,6	20,2	78	0,6708	2,2	3731,2465
2014	12	7	0,2	7,3333	27	20,6	90	0,375	12,3	1490,8487
2014	12	8	6,1	6	32,2	22,6	74	0,3542	46	3681,748
2014	12	9	2,5	6,6667	29,4	21,5	80	0,5625	0,9	2593,9588
2014	12	10	4,9	6,6667	31,7	22,1	74	0,0792	19,4	3791,3519
2014	12	11	3,4	7,3333	29	21,4	83	0,5583	0,6	3614,5714
2014	12	12	8	5,3333	31,6	21,9	68	0,6542	0	5355,2698
2014	12	13	4,7	6,6667	30,6	23,1	76	1,3083	1,6	2391,2505
2014	12	14	5	5,3333	30	22,2	81	0,5708	34,6	3591,0007
2014	12	15	5,8	6	30,4	21,6	78	0,3375	0	4668,1831
2014	12	16	5,6	7,3333	31,3	22,4	74	0,4375	0,7	3347,0436
2014	12	17	6,3	5,3333	31,2	24	71	0,5583	1,5	4611,6133
2014	12	18	7,8	5,3333	32,2	23,8	73	0,4833	20,8	4876,784
2014	12	19	6,4	5,3333	31,2	22,8	75	0,7042	3,5	4397,1197
2014	12	20	7,3	6,6667	31,6	23,1	70	0,6708	1	4695,2894
2014	12	21	6,9	5,3333	31,4	23,4	75	0,7417	5,5	5106,5986
2014	12	22	8,5	5,3333	33,5	23,3	69	0,4292	0	5834,9342
2014	12	23	8,8	2	34,1	21,5	62	0,9917	0	3916,2768
2014	12	24	3,7	4,6667	32,8	21,6	63	0,8042	0,5	2905,0925
2014	12	25	6,4	5,3333	32,5	22,6	68	0,7542	0,2	3570,9656
2014	12	26	7,4	4,6667	34	23,2	58	0,4167	0	4432,4758
2014	12	27	4,7	6,6667	32,7	24	65	0,8042	0	4848,4991
2014	12	28	4,9	4,6667	32,3	23,6	63	0,4417	0	2998,1968
2014	12	29	7,6	3,3333	34,6	21,8	62	0,2833	0	6328,741
2014	12	30	7,8	6	33,6	22,1	65	0,2958	0	4837,8923
2014	12	31	7,1	4,6667	32,9	22,3	62	0,4125	0	4457,225
2015	1	1	4,7	5,3333	33	22,3	64	0,0458	0	4373,5489
2015	1	2	8,8	4	35,2	22,6	53	0,7292	0	4052,987
2015	1	3	8,9	3,3333	35	21,8	50	0,5708	0	2609,2798
2015	1	4	8,8	2	35	22	49	0,5125	0	3436,6124
2015	1	5	5,5	3,3333	34,2	21,4	55	0,3583	0	0
2015	1	6	8,9	2	35,2	20,8	47	0,825	0	0

2015	1	7	7,3	3,3333	35,2	20,2	48	0,4292	0	2754,2398
2015	1	8	3,2	8	33,6	20,4	50	0,1417	0	1857,3735
2015	1	9	2,9	7,3333	33,5	24,4	56	0,6167	0	2469,034
2015	1	10	7,9	2	36,6	23,2	52	0,1833	0	4514,9733
2015	1	11	3,2	6	33,3	23	54	0,4417	0	2833,2017
2015	1	12	8,2	4,6667	35,5	24,7	47	1,0792	0	2327,6096
2015	1	13	9,1	2	36,5	22,8	49	1,0333	0	2018,833
2015	1	14	7	6,6667	34,9	23,2	56	1,1458	0	4783,6796
2015	1	15	8,8	6	36,3	24,5	51	1,2833	0	4748,3235
2015	1	16	4,4	6	34,4	24,6	58	0,9417	0	3838,4934
2015	1	17	2,6	6,6667	30,9	22,6	71	1,0167	9,3	2408,9286
2015	1	18	6,8	7,3333	32	21,6	71	1,0583	0	2997,0183
2015	1	19	2,9	8	30,8	21,9	68	0,4708	1,6	3116,0505
2015	1	20	4,6	7,3333	30,3	22,8	64	1,4083	0	2827,309
2015	1	21	4,2	7,3333	31,8	22,8	71	0,4208	3,4	3598,0719
2015	1	22	1,7	7,3333	27,7	22,2	77	1,1375	0	750,72775
2015	1	23	5,1	7,3333	32	21,7	66	0,3833	0,3	790,79799
2015	1	24	3,3	7,3333	29,9	22	72	0,4958	3,6	2219,1842
2015	1	25	7,6	4	34,4	22,4	66	0,3042	0	5627,5118
2015	1	26	8,5	4,6667	33,6	22,5	62	0,3542	9,1	3998,7743
2015	1	27	6	6	31,8	23,1	73	0,85	14,1	4372,3704
2015	1	28	8,5	6,6667	33,6	22,5	65	0,5083	0	3838,4934
2015	1	29	7,1	6	32,7	24,1	62	0,35	0	4967,5313
2015	1	30	4,6	8	32,6	24,2	59	0,3333	0	4031,7733
2015	1	31	4,2	6,6667	31,8	24,1	66	0,6833	0,5	1599,274
2015	2	1	6,3	6,6667	32,9	23,3	63	1,2292	0,1	2401,8574
2015	2	2	4,1	6,6667	34,8	23,3	51	1,7958	0,1	3205,6193
2015	2	3	3,5	7,3333	33,6	23,8	54	2,05	0	1586,3101
2015	2	4	4,5	6,6667	32,6	24,7	56	1,1917	0	3385,9353
2015	2	5	4,9	6	34,7	25,3	49	0,8	0	3213,869
2015	2	6	2,4	8	33,4	24,9	63	0,8333	0,4	3845,5646
2015	2	7	6,5	7,3333	33,6	23	66	0,7708	30,1	3283,4027
2015	2	8	0,8	7,3333	29,2	22,2	82	0,625	36,2	2242,7549
2015	2	9	5,7	6,6667	30,5	21,9	74	0,1583	7,1	3862,0641
2015	2	10	3,5	7,3333	29,7	22	81	0,4292	1,6	3387,1139
2015	2	11	2,9	6,6667	31,1	22,4	73	0,225	2	3976,3821
2015	2	12	0,3	8	29	22,7	77	0,15	0	1646,4155
2015	2	13	3,4	6	32,4	23,4	67	0,35	0	2938,0915

2015	2	14	4,9	7,3333	32,1	23,7	66	0,8917	0	3205,6193
2015	2	15	5,4	7,3333	33	24,4	70	0,2083	0	4065,9509
2015	2	16	10,5	4,6667	35	25	57	0,4625	0	4923,9255
2015	2	17	10,3	4,6667	35,4	23,6	52	0,7292	15,3	6815,4765
2015	2	18	8,2	7,3333	33,4	23	68	0,4792	0	6246,2434
2015	2	19	8,8	4	34,4	23	55	2,7375	0	4089,5216
2015	2	20	8,9	3,3333	33,8	25,2	59	1,9167	0,2	4019,988
2015	2	21	9	5,3333	34,7	24,2	56	1,1667	0,4	3573,3226
2015	2	22	7,9	4,6667	33,8	24,2	59	0,2	0	2644,6359
2015	2	23	9,4	6	36,1	23,5	48	0,4167	0	0
2015	2	24	9	6	34,8	23,4	54	0,2667	0	2867,3793
2015	2	25	3,8	6,6667	33,1	24,1	63	0,875	0	2857,951
2015	2	26	8,6	3,3333	35,7	22,9	53	0,4125	0	4386,5128
2015	2	27	6,7	4,6667	35	23,1	55	0,2292	0	3261,0105
2015	2	28	7,7	6	35	23,8	55	0,65	0	4662,2904
2015	3	1	6,6	6,6667	34,8	23,8	61	0,9042	50,6	3464,8973
2015	3	2	7,8	6,6667	32	21,2	70	1,0333	0	3575,6797
2015	3	3	2,6	7,3333	30,4	21,7	70	0,775	0,1	3561,5373
2015	3	4	6,3	6,6667	33,3	24,6	62	1,1917	0	3299,9022
2015	3	5	9,8	6	35,5	22,9	53	0,8542	0	1562,7394
2015	3	6	6,8	8	34,1	23,2	60	0,9083	3,7	3351,7578
2015	3	7	4,1	8	32,2	24,6	67	0,4375	0	2177,9354
2015	3	8	5	6	33,3	24,2	53	0,4083	0	4274,5519
2015	3	9	1,9	7,3333	32,1	24,2	62	0,4042	0,2	750,72775
2015	3	10	4,3	8	33,6	25	58	1,4375	0	1554,4896
2015	3	11	6,6	6	34,9	25,4	54	0,525	0	2259,2545
2015	3	12	9,7	3,3333	36,8	24	51	0,4167	0	5456,624
2015	3	13	8,6	6,6667	36,1	24,8	59	0,625	0,2	4677,6113
2015	3	14	7,4	6,6667	35,5	24,9	61	0,8542	5,5	5368,2337
2015	3	15	8,9	4,6667	35,3	24,3	63	0,6167	0	5896,2181
2015	3	16	7,4	4,6667	35,2	24,5	59	0,8042	0	4822,5713
2015	3	17	5,3	6,6667	34,1	25	62	0,8583	16,8	3410,6846
2015	3	18	0	8	31,3	22,4	87	0,4042	1,5	2494,9618
2015	3	19	3,1	8	31,7	22,8	72	1,2875	0	2350,0018
2015	3	20	3	8	31,7	23,2	69	0,375	31,5	2691,7774
2015	3	21	3,1	7,3333	30	21,7	78	0,3042	0,3	3202,0837
2015	3	22	7,7	6,6667	32,6	21,9	64	0,4708	1	3259,8319
2015	3	23	4,1	8	29,7	23,4	77	1,1958	0,4	2783,7032

2015	3	24	5,6	7,3333	31,2	23,3	73	0,9458	8,8	5052,3859
2015	3	25	4	7,3333	31,3	23,2	75	1,2792	0,4	3421,2914
2015	3	26	4,9	8	32,2	23,2	70	0,5792	0	4625,7557
2015	3	27	6,7	5,3333	33,7	23,6	65	0,6042	0	4512,6162
2015	3	28	1,1	8	31,2	23,6	70	0,0917	12,1	3308,1519
2015	3	29	0	8	28,8	21,8	94	0,9417	19,2	813,19018
2015	3	30	0,3	7,3333	29,2	21,6	79	0,2125	0	3628,7139
2015	3	31	7,1	5,3333	33,4	21,8	70	0,3792	0	4894,4621
2015	4	1	7,8	4,6667	34,3	22,5	66	0,5125	0	3296,3666
2015	4	2	1,7	8	30	22,7	67	0,7125	0,3	2466,6769
2015	4	3	1,8	8	30	23,8	68	1,3333	1	3889,1704
2015	4	4	7,7	8	33,5	23,3	61	0,4792	0	3804,3158
2015	4	5	7,4	7,3333	32,8	23,2	69	0,3833	0	4417,1548
2015	4	6	5,7	8	33,9	23,4	63	0,8792	0	4556,2221
2015	4	7	4,2	4	32,4	24,5	62	1,6208	0	3316,4017
2015	4	8	3,3	6	32,8	24,5	59	0,675	0,1	2840,2729
2015	4	9	7,4	5,3333	34,5	24,3	51	1,0208	0	4371,1919
2015	4	10	3,8	7,3333	34,2	24,8	53	1,45	0	3755,9958
2015	4	11	2,4	8	33,2	25,1	50	1,9292	0,3	2169,6857
2015	4	12	5,4	7,3333	33,1	23,2	64	2,2125	0	3202,0837
2015	4	13	7,5	7,3333	35,4	23,8	51	0,7792	0	4189,6972
2015	4	14	4,9	6	33,9	24,6	55	0,725	0	4190,8758
2015	4	15	8,6	7,3333	34	24,1	56	0,8167	15,9	4312,265
2015	4	16	6,2	6,6667	32,2	22	77	0,6667	40,2	5158,4542
2015	4	17	4,1	7,3333	28,5	22,2	83	1,2	27,4	3001,7324
2015	4	18	7,5	6,6667	33	22,2	74	0,4958	0	3616,9285
2015	4	19	7,3	5,3333	32,8	22,3	67	0,5417	0	1040,6477
2015	4	20	8	8	32,4	23,4	69	0,4375	0	4910,9616
2015	4	21	4,5	7,3333	31,4	23,6	68	1,025	0,1	4414,7977
2015	4	22	7,4	7,3333	34,3	22,7	64	0,6917	0	3127,8359
2015	4	23	3,9	7,3333	31,5	23,5	64	1,5167	0	2374,751
2015	4	24	7,1	6,6667	35,8	23,6	57	1,7917	0	3051,231
2015	4	25	2,6	7,3333	31,6	23,8	66	2,25	0	2641,1003
2015	4	26	5,5	5,3333	35,3	24,4	59	1,8	0	2841,4515
2015	4	27	8,8	6,6667	35,7	24,7	54	2,2625	0,2	3917,4553
2015	4	28	0,3	8	32,2	24,7	70	0,9083	0	3284,5812
2015	4	29	9,9	6	36,7	23,4	53	0,9042	0	4914,4972
2015	4	30	1,6	7,3333	32,5	23,4	60	1,1667	0,1	2763,6681

2015	5	1	0,4	7,3333	31,3	23,3	69	0,1083	0	3543,8592
2015	5	2	7,9	6,6667	34,2	21,6	60	0,3583	0	5006,423
2015	5	3	8,6	7,3333	35,4	22	57	0,4625	0	0
2015	5	4	6,2	6	34,8	23,9	59	0,4083	0	991,14919
2015	5	5	6,7	7,3333	35,2	23,9	54	0,5708	0	2757,7754
2015	5	6	7,3	6	35,5	25,3	46	1,6167	0	4107,1997
2015	5	7	9,3	5,3333	36,6	23,6	48	2,0458	0,2	4882,6767
2015	5	8	4,1	6	32,5	23,9	59	1,3375	0,1	2570,3881
2015	5	9	3,4	6	34	24,8	54	1,6	0,4	1104,2887
2015	5	10	4,9	7,3333	33,2	23	63	1,0542	0,1	2238,0408
2015	5	11	4,7	7,3333	35,3	23,7	51	1,1958	0	3447,2192
2015	5	12	4	7,3333	34,7	23,7	56	0,7083	0,1	1910,4077
2015	5	13	1,6	8	32,2	24,1	54	2,3	0,1	1203,2858
2015	5	14	0	8	29,8	24,2	73	2,2792	0,5	1253,9628
2015	5	15	6,4	6,6667	36	23,6	54	0,9708	3,4	3500,2534
2015	5	16	5,1	8	34,8	23,5	61	0,7167	0	3455,469
2015	5	17	2,5	7,3333	34,4	23,5	55	0,3125	0	3388,2924
2015	5	18	0,5	8	31,9	25,6	60	1,9083	0	2262,7901
2015	5	19	5,2	4	35,6	24,2	51	0,9542	0,1	4094,2358
2015	5	20	7,9	6	36,4	25	54	2,05	0	4189,6972
2015	5	21	5,5	6	34,2	24,6	51	2,0917	0	4533,8299
2015	5	22	2,5	5,3333	33,2	23,8	55	1,1083	0	3119,5861
2015	5	23	1,5	8	31,8	24	58	0,7125	0	2041,2252
2015	5	24	9,1	5,3333	37	23,7	51	0,5083	5,2	6326,3839
2015	5	25	3,2	6	32,8	23,7	67	0,1917	0	2499,6759
2015	5	26	7,1	7,3333	35,2	23,8	59	1,175	0,2	4682,3255
2015	5	27	5,1	7,3333	31,8	24,2	60	2,0792	0,1	2795,4886
2015	5	28	3,9	7,3333	32,4	24,6	61	0,9417	0,7	2126,0798
2015	5	29	1,9	7,3333	30,8	22,4	75	0,8167	0	2855,5939
2015	5	30	5	6	31,3	22,8	75	0,3208	1,1	4253,3382
2015	5	31	8,1	4,6667	34,7	23,8	59	0,8333	0,3	3329,3656
2015	6	1	4,8	7,3333	30,4	23,3	80	0,125	3,5	3464,8973
2015	6	2	9,6	6	35,8	23,1	57	0,8125	0	3766,6026
2015	6	3	5,5	8	33,2	23,6	62	3,075	0	3595,7148
2015	6	4	5,7	6,6667	33,1	23,6	56	2,7917	2,1	3655,8202
2015	6	5	5	7,3333	32,8	22,2	67	2,1833	0,3	2042,4037
2015	6	6	8,4	4,6667	33,8	22,2	49	2,5083	0	5026,4581
2015	6	7	3,1	8	32,6	23,1	57	0,6708	0	3263,3676

2015	6	8	5,1	7,3333	34,5	23,5	54	1,3375	0,4	4259,2309
2015	6	9	5,7	7,3333	34,2	23,8	60	0,7208	0,4	4940,425
2015	6	10	4,6	6	32,1	23,6	65	0,2542	0	3755,9958
2015	6	11	5,4	7,3333	32,2	23,9	61	0,55	0,2	3060,6593
2015	6	12	6,5	6	35,7	25,2	47	0,7667	0	3262,189
2015	6	13	2,7	6	32,8	24,3	62	0,9458	0,7	3263,3676
2015	6	14	6,8	6,6667	35	23,2	55	0,9208	0,1	4346,4426
2015	6	15	3,8	7,3333	34,6	23,3	56	0,7	0,1	3388,2924
2015	6	16	6,6	6	35,2	24,4	50	1,0667	0	2573,9237
2015	6	17	6,1	6,6667	36,1	25,2	47	0,8625	0	4506,7236
2015	6	18	4,7	8	35,4	25,4	42	0,975	0	2850,8798
2015	6	19	7,9	7,3333	35,6	24,7	51	2,2208	0	2723,5978
2015	6	20	7,6	6,6667	34,8	24,6	51	1,7125	0	2553,8886
2015	6	21	1,6	8	32,2	24,8	55	2,6333	0	3694,7119
2015	6	22	4,5	7,3333	33,5	24,6	49	3,775	0	3206,7978
2015	6	23	4	5,3333	33,6	24,6	48	3,6917	0	2760,1325
2015	6	24	7	6	33,8	24,9	48	2,0542	0	2479,6408
2015	6	25	3,8	8	34,7	24,7	43	2,3583	0,7	1495,5628
2015	6	26	4,4	8	32	22,9	53	2,1625	0	1785,4828
2015	6	27	1,9	7,3333	32,5	23,7	52	3,4542	0	837,93945
2015	6	28	1,8	8	30,7	24,5	54	3,1458	0,5	1389,4945
2015	6	29	3,6	7,3333	32,7	22,5	55	2,3	0	2202,6847
2015	6	30	0,9	7,3333	32,6	23,1	50	0,7167	0	3784,2807
2015	7	1	6,7	6,6667	36	23,8	46	1,2917	0	3887,9919
2015	7	2	8,6	5,3333	36,6	24,6	43	1,0958	0,3	4478,4387
2015	7	3	8,9	5,3333	37,6	24,5	41	0,9625	0	5067,7069
2015	7	4	6,9	7,3333	36,5	24	41	1,375	0	3876,2065
2015	7	5	3,6	8	35,2	25,8	46	0,9125	0	2980,5188
2015	7	6	2,1	8	34,9	26,2	47	1,2583	0	3859,707
2015	7	7	4,4	7,3333	35,9	25,9	46	1,0083	0	4064,7724
2015	7	8	7,7	4,6667	36,8	25,1	47	0,2542	0	5788,9713
2015	7	9	5	7,3333	35,1	23,3	47	0,9	0,2	4276,9089
2015	7	10	6	7,3333	34,4	23,4	58	1,2042	1,6	3431,8983
2015	7	11	4,6	5,3333	34,6	22,6	47	1,5375	0	2502,033
2015	7	12	3,7	7,3333	34,6	24,9	50	1,7083	0	2860,3081
2015	7	13	9,8	4,6667	36,4	23,1	43	0,8167	0	2268,6827
2015	7	14	5,2	7,3333	34,2	23,6	46	1,9125	0	2816,7022
2015	7	15	2,9	6	36	26,1	45	0,2958	0	3244,511

2015	7	16	3,7	7,3333	35,4	26	47	1,4625	0	4538,544
2015	7	17	7,8	6,6667	36,3	24,6	40	1,3583	0	4360,585
2015	7	18	2,2	8	32,9	25,3	47	2,3	0	3400,0778
2015	7	19	5,6	4,6667	34,4	23	51	0,8	0,1	4617,506
2015	7	20	5,3	7,3333	35,1	23,5	53	0,5917	0	3770,1382
2015	7	21	5,8	7,3333	35,8	23,8	55	1,05	0,1	3889,1704
2015	7	22	2,8	8	34	24	59	2,7083	0	1269,2838
2015	7	23	2,4	7,3333	32,3	24,2	53	1,8417	0	1926,9072
2015	7	24	5,5	7,3333	35,1	21,3	48	1,7125	0	2154,3647
2015	7	25	6,5	5,3333	35	21,8	42	2,4833	0	4111,9138
2015	7	26	4,1	6	34	24,2	44	2,9875	0	2962,8407
2015	7	27	3,1	8	33	25,4	48	2,8542	0	3106,6222
2015	7	28	7,6	7,3333	33,3	25,2	54	3,4417	2,3	2952,2339
2015	7	29	3,5	7,3333	30,6	22,6	62	3,6667	3,9	3506,1461
2015	7	30	3,8	8	32,8	21,9	60	1,9333	0	3120,7646
2015	7	31	7,5	7,6667	34,5	22,2	48	3,4292	0	1971,6916
2015	8	1	6,8	8	35,4	24,9	47	2,1333	0	4456,0465
2015	8	2	8,1	6	36,2	25,1	42	2,8792	0	3809,0299
2015	8	3	7	4,6667	35,4	25	42	2,925	0	3185,5841
2015	8	4	4,1	6	36,5	25,7	45	2,2208	0	2603,3871
2015	8	5	5,5	6	35,4	26,3	44	2,6625	0	2827,309
2015	8	6	7,9	5,3333	36,4	25,2	39	2,6833	0	4563,2933
2015	8	7	2,9	8	33,3	24,8	47	3,7958	0	2392,4291
2015	8	8	2	8	34,8	25,6	49	0,95	0,4	2803,7383
2015	8	9	1,3	8	32,8	23,4	50	0,3708	0	744,83506
2015	8	10	6,1	5,3333	36,1	23,6	45	0,8375	0	1767,8047
2015	8	11	2,6	7,3333	35,3	24,2	48	0,9458	0	3361,1861
2015	8	12	4,1	6,6667	34,5	25,4	45	1,4667	0	2740,0973
2015	8	13	5,5	7,3333	36,6	25,4	37	2,1583	0	2790,7744
2015	8	14	3,7	7,3333	33,2	26,1	52	4,2542	2,9	2998,1968
2015	8	15	7	5,3333	32,9	22	59	2,6167	0,5	2418,3569
2015	8	16	1,7	8	32,5	22,2	54	2,9	0	1850,3023
2015	8	17	9,2	6,6667	34,5	25,7	41	3,9	0	4531,4728
2015	8	18	9,5	3,3333	36,8	24,7	43	2,2833	0	38,891704
2015	8	19	4,3	6	34,5	23,7	49	2,3875	0	2817,8808
2015	8	20	7,7	7,3333	35,8	23,8	38	4,2792	0	3459,0046
2015	8	21	3,2	8	33,6	27	36	3,1417	0	2542,1032
2015	8	22	5,7	7,3333	35,7	26,5	38	3,575	0	3779,5665

2015	8	23	7,5	8	37,2	26,2	35	3,2875	0	4661,1118
2015	8	24	7,2	6	35,8	26,8	39	3,525	0	4357,0494
2015	8	25	4,2	6	32,5	26,8	52	2,5875	0,4	1799,6252
2015	8	26	3	8	34,1	25	45	0,8875	0	1376,5306
2015	8	27	2,6	7,3333	36,2	25,3	46	1,0917	0	3922,1694
2015	8	28	7,5	6	37,4	25,5	42	1,6792	0,3	4114,2709
2015	8	29	4,4	7,3333	36,2	25,1	42	2,975	0	3978,7392
2015	8	30	1	8	31,4	25,9	50	2,4083	0	3057,1237
2015	8	31	1,1	8	33,7	24,8	45	2,6	0	2922,7705
2015	9	1	5,7	7,3333	36,4	25,5	38	2,5625	0,2	4018,8094
2015	9	2	4,1	7,3333	33,6	25,2	47	2,975	0	3299,9022
2015	9	3	6,8	6,6667	36,7	24,3	37	1,9542	0	4433,6543
2015	9	4	6,6	6	37,2	25,2	37	1,4875	0	5118,384
2015	9	5	3,6	7,3333	35,4	25,3	41	1,4875	0,7	4440,7255
2015	9	6	0,5	8	33,1	23,4	74	1,2458	0	768,40579
2015	9	7	5,8	7,3333	36,4	23,4	47	0,9667	0	2642,2788
2015	9	8	7,9	8	36,8	23,6	53	1,2083	1,1	4570,3645
2015	9	9	3,5	6,6667	36,6	24,6	43	1,1167	0	3932,7763
2015	9	10	3	7,3333	36,8	25	42	0,5917	0,2	4234,4816
2015	9	11	2,5	8	33,6	23,1	54	1,8958	0	1383,6018
2015	9	12	10,1	5,3333	38,4	23,5	39	1,6083	0	0
2015	9	13	10	3,3333	38,1	23,7	32	1,675	0	0
2015	9	14	6,2	6	36,8	25,1	34	1,6667	0	0
2015	9	15	4,3	4	35,3	25,7	38	1,4333	0	208,60096
2015	9	16	5,3	4	36,7	25,5	40	0,9125	0	3176,1558
2015	9	17	7,4	7,3333	36,6	25,2	39	0,5958	0	4300,4797
2015	9	18	8,1	7,3333	37,7	25,7	44	0,9417	0	4518,5089
2015	9	19	5,4	7,3333	36,9	26,2	47	1,8333	0	4441,904
2015	9	20	2	7,3333	35,6	26,7	38	1,4708	0	3837,3148
2015	9	21	8,5	4,6667	38,3	25,8	36	1,4583	0	2839,0944
2015	9	22	6,2	5,3333	38,2	27	31	1,5333	0	4745,9665
2015	9	23	5	7,3333	37,9	26,8	37	1,1167	0	4986,3879
2015	9	24	8,8	6,6667	39,2	25,6	35	0,7542	0	4664,6474
2015	9	25	7	5,3333	38,6	25,2	38	0,4708	0	0
2015	9	26	6,6	6	36,8	25,8	35	1,0958	0	2514,9969
2015	9	27	7,1	6,6667	36,4	26,9	37	0,875	0	3918,6338
2015	9	28	9,7	3,3333	39,2	24,8	31	0,725	0	0
2015	9	29	8	5,3333	38,5	25,7	34	0,7667	0	1871,516

2015	9	30	6,5	6	35	24,3	50	1,3042	7,6	3829,0651
2015	10	1	1,9	6	32,9	23,6	83	0,2375	6,8	967,57846
2015	10	2	3,8	7,3333	35,2	22,5	62	0,425	0	581,01849
2015	10	3	2,9	6	33,6	23,9	59	0,5208	0,2	4004,667
2015	10	4	6,7	7,3333	37,3	25,7	41	0,6833	0,3	4920,3899
2015	10	5	6,9	6	37,6	25,3	38	0,9458	0	1618,1306
2015	10	6	4,9	5,3333	37,4	25,6	38	0,9958	0	1763,0906
2015	10	7	5,8	8	37,5	24,3	40	0,8208	0	4604,5421
2015	10	8	5,2	7,3333	37,6	25,5	44	0,3667	0	4045,9158
2015	10	9	4,8	7,3333	36,3	26,6	43	0,5708	0,2	4862,6416
2015	10	10	7	6	36,8	25,4	57	0,6667	2	3702,9617
2015	10	11	6,6	5,3333	34,2	22,4	64	0,4833	2,6	3561,5373
2015	10	12	2	8	31,6	22,6	68	0,6917	0	3393,0066
2015	10	13	5,7	7,3333	36	23,6	56	1,0333	4,6	3787,8163
2015	10	14	6,1	6,6667	35,4	23,8	63	0,6208	2,8	4564,4718
2015	10	15	2,4	7,3333	31,1	23,1	76	0,2833	1,3	3904,4914
2015	10	16	3,5	7,3333	32,1	23	64	1,2917	1,1	4009,3812
2015	10	17	2,4	6	33,6	23,3	57	0,825	0,1	2987,59
2015	10	18	0,4	7,3333	32,6	24,8	53	0,8	0	2684,7061
2015	10	19	9,5	3,3333	37,2	23,6	44	1,0042	0	2565,6739
2015	10	20	9,4	3,3333	38,5	24,4	39	1,6792	0	0
2015	10	21	8,9	6,6667	38,5	24,6	35	1,2083	0	0
2015	10	22	8,6	5,3333	36,4	24,4	46	0,5	0	3235,0827
2015	10	23	5,1	4	36,4	26,4	46	0,9083	0	1824,3745
2015	10	24	6,5	6,6667	36,7	25	49	1,0583	0,4	513,84191
2015	10	25	4,9	6,6667	35,3	24,9	58	0,9667	0	5380,0191
2015	10	26	6,4	5,3333	37,2	24,5	47	0,9	0	4360,585
2015	10	27	4,8	6	35,6	25,2	44	1,1625	0	4114,2709
2015	10	28	4,2	6,6667	36,4	26,3	49	1,5667	0	2291,0749
2015	10	29	7,6	4,6667	37,2	24,3	44	1,3833	0	0
2015	10	30	8,7	4,6667	37,3	24,8	48	1,4083	0	1790,1969
2015	10	31	5,6	8	35,2	25,7	57	2,15	0	0
2015	11	1	2,9	7,3333	34,5	26,2	55	2,5833	5,3	4162,5909
2015	11	2	1,1	7,3333	30,4	22,1	80	1,1042	0,9	3197,3695
2015	11	3	6,9	8	33,5	22,6	63	1,35	6,6	3363,5432
2015	11	4	4,6	7,3333	31,9	24	72	1,5833	17,4	3912,7412
2015	11	5	1,1	7,3333	28,8	23,1	87	0,7833	23,3	2833,2017
2015	11	6	6	5,3333	34	23	70	1,0625	25	3611,0358

2015	11	7	0	8	28,8	22,5	88	1,3208	6,2	2454,8915
2015	11	8	5,6	6,6667	33,7	22,4	63	0,8208	0	3609,8573
2015	11	9	4,1	6	34,2	22,5	56	1,6	0	2992,3042
2015	11	10	10,4	5,3333	36,6	24,3	46	1,2792	0	5293,9859
2015	11	11	5,6	6	35,2	25,8	46	1,4833	0	3150,228
2015	11	12	5,6	7,3333	34,8	25,3	52	1,7208	0	2399,5003
2015	11	13	6,4	6	34,9	24,9	48	1,3583	0	603,41068
2015	11	14	4,2	6,6667	35,3	25,2	45	1,7125	0	2498,4974
2015	11	15	3,8	7,3333	34,5	25,4	50	1,7375	0	2599,8515
2015	11	16	6	8	35,9	25	46	1,3792	0,1	4133,1275
2015	11	17	2,3	7,3333	32,8	24,4	62	1,775	1,8	2307,5745
2015	11	18	2,9	6	32,2	22,8	67	0,9542	0	2354,7159
2015	11	19	7	5,3333	33,6	23,2	61	2,3833	0	1970,513
2015	11	20	6,9	5,3333	35,6	25,1	57	1,8958	39,5	4428,9401
2015	11	21	6,1	6,6667	32,3	21,2	71	1,4167	0,1	3942,2046
2015	11	22	6,4	5,3333	34,4	22,3	62	0,875	0	4893,2835
2015	11	23	3,3	6	33,5	25,1	60	0,9958	1,6	4051,8085
2015	11	24	5,4	7,3333	32,3	23,4	66	0,8375	0	1632,273
2015	11	25	5,6	5,3333	32,8	23,7	64	1,0333	1,1	1418,9579
2015	11	26	5,9	5,3333	34,3	23,7	67	0,55	0	2253,3618
2015	11	27	6,9	6	34,8	24,1	62	1,1375	0	0
2015	11	28	8,1	5,3333	35,5	24,2	61	2,1667	3,4	2133,1511
2015	11	29	5,5	5,3333	32,9	22,9	70	1,4333	0	3348,2222
2015	11	30	1,3	7,3333	31,9	23,3	69	1,425	0	2161,4359
2015	12	1	2	8	31,7	24,8	62	2,0792	0	2227,434
2015	12	2	5	6	34	25	48	2,375	0	1447,2428
2015	12	3	2,7	6,6667	32,5	22,8	54	1,5708	0	1149,0731
2015	12	4	1,8	7,3333	32,2	23	59	1,3708	0	2623,4222
2015	12	5	7,7	5,3333	34,6	23,5	59	0,9333	0	2353,5374
2015	12	6	8,7	3,3333	36,5	24	49	0,975	0	0
2015	12	7	4,7	4	34,7	24	52	1,2583	0	1789,0184
2015	12	8	6,8	4,6667	34,8	23,9	47	1,8125	0	1852,6594
2015	12	9	8,2	5,3333	36	23,8	49	1,1167	0	3337,6153
2015	12	10	6,9	5,3333	35,4	24,5	47	1,9042	0	945,18627
2015	12	11	7,9	3,3333	36,8	24,4	39	2,1083	0	0
2015	12	12	8,6	3,3333	37,1	21,8	43	1,6458	0	2266,3257
2015	12	13	3,5	6,6667	34,8	22,6	48	1,2458	0	2875,629
2015	12	14	5,6	6,6667	35,8	25,4	47	1,2667	0	3975,2036

2015	12	15	3,8	6,6667	32,2	25,3	70	1,3375	0,6	3231,5471
2015	12	16	5,1	6	34,4	24,6	56	0,7708	0	2854,4154
2015	12	17	0,9	8	33,4	25	51	1,7167	0	2220,3628
2015	12	18	0,8	7,3333	32,4	25,9	57	1,3708	0	2496,1403
2015	12	19	2,9	6	33,7	24,4	58	1,8167	0	2536,2105
2015	12	20	6,5	3,3333	35,8	22,7	46	1,8917	0	2621,0652
2015	12	21	5,9	3,3333	35,5	21,9	42	2,2875	0	0
2015	12	22	7,3	3,3333	35,9	23,7	45	1,8	0	2419,5354
2015	12	23	8,3	3,3333	37,9	24	41	1,4417	0	3199,7266
2015	12	24	7,7	2	38,2	23,3	40	1,5	0	0
2015	12	25	4,4	6,6667	35,8	23,3	43	1,3792	0	2730,6691
2015	12	26	7,1	3,3333	37,7	24	42	1,5083	0	5915,0747
2015	12	27	8,2	2	37,9	25,2	40	1,9167	0	6461,9156
2015	12	28	5,2	5,3333	36,2	25,8	40	1,5958	0	3688,8192
2015	12	29	6,8	4,6667	36,4	24,6	44	1,575	0	3354,1149
2015	12	30	2,6	6,6667	34,7	25,7	46	0,9917	0	947,54334
2015	12	31	6	4,6667	36,9	26	39	3,0042	0	1863,2662
2016	1	1	4	6	37	25,8	43	2,3417	0	2658,7783
2016	1	2	0,3	8	33,8	24,8	52	0,8042	0	2414,8213
2016	1	3	6,9	6	37,2	23,1	48	1,1125	0	4556,2221
2016	1	4	3,8	8	35,6	23,1	49	1,2	0	2021,1901
2016	1	5	4,8	6,6667	35,7	26	58	0,9083	19,6	2763,6681
2016	1	6	6,3	6,6667	33	23,2	77	1,2333	5,9	3818,4582
2016	1	7	7,8	6,6667	35,2	23,2	63	1,1208	12,6	5408,304
2016	1	8	1,5	7,3333	31,6	23,6	0	0,5042	12,2	2063,6174
2016	1	9	6,6	5,3333	34,3	23	71	0,9792	0	2408,9286
2016	1	10	6	6	33,9	24,8	64	1,6667	0	3739,4963
2016	1	11	3,9	6,6667	34,4	24,9	53	3,0792	0	2430,1422
2016	1	12	7,3	6	35,1	24,8	57	1,1292	0	5567,4064
2016	1	13	8,5	6,6667	35,1	25	49	2,0625	0	5166,704
2016	1	14	7,7	6,6667	35	26,6	52	2,0333	0	5668,7605
2016	1	15	8,5	6	35,7	26,4	57	1,4167	0	1823,196
2016	1	16	8,7	3,3333	35,9	24,5	53	0,9083	0	2972,269
2016	1	17	6,6	4,6667	33,9	24,8	61	1,4042	0	3809,0299
2016	1	18	7,9	4,6667	36,9	25,5	53	1,875	0	4055,3441
2016	1	19	7,9	5,3333	36	26,7	53	2,4542	0	3753,6387
2016	1	20	7,1	6,6667	35,8	27,2	48	1,2917	0	4834,3567
2016	1	21	4,8	6,6667	35,8	27	55	1,2167	0	3714,747

2016	1	22	7,6	6,6667	36,6	26	52	0,9292	0	4577,4357
2016	1	23	6,8	3,3333	37,5	26	46	1,075	0	6147,2463
2016	1	24	7,5	4	37,4	26,2	48	1,9333	2,2	3771,3168
2016	1	25	4,5	6	34,8	22,6	68	1,6	0,1	3747,746
2016	1	26	7	4,6667	35,6	22,8	54	0,8625	0	2797,8456
2016	1	27	9,6	2	37,2	25,3	43	1,05	0	0
2016	1	28	9,3	2	36,9	22,9	44	0,7792	0	0
2016	1	29	7,8	4,6667	36,3	22,9	53	1,5583	0	2524,4252
2016	1	30	8,4	3,3333	36,1	25	53	1,9958	0	4888,5694
2016	1	31	8,4	5,3333	36,3	25,3	50	1,7375	0	2119,0086
2016	2	1	8,9	5,3333	36,9	27,2	45	1,3583	0	0
2016	2	2	8,7	2	37,5	22,8	44	1,2333	0	2777,8105
2016	2	3	8,9	2	37,2	22,8	44	1,15	0	5213,8454
2016	2	4	1,9	5,3333	34,3	26,8	50	1,8125	0,4	2854,4154
2016	2	5	2,2	7,3333	32,4	23,8	72	1,8625	0	2095,4379
2016	2	6	5,5	5,3333	33,2	24,1	66	1,3417	0	2595,1374
2016	2	7	2,1	7,3333	33,5	24,6	54	1,5708	0	2281,6467
2016	2	8	1	8	31,4	25,3	64	1,275	0	2635,2076
2016	2	9	3,4	8	34,5	25,2	59	1,5667	0,3	3371,7929
2016	2	10	3,2	7,3333	32,5	24,1	66	1,5167	0,3	2529,1393
2016	2	11	10,1	4,6667	38,3	24,1	45	1,3833	0	5989,3225
2016	2	12	7,2	7,3333	36,9	25,2	46	1,1167	0	3017,0534
2016	2	13	4,7	7,3333	35,8	24,6	51	0,7292	0	2949,8768
2016	2	14	1,9	6,6667	34,5	24,8	47	0,6542	0	1693,5569
2016	2	15	0,4	8	32,7	26	56	1,4292	0	1185,6077
2016	2	16	8,2	4	38	25,4	42	1,8333	0	2558,6027
2016	2	17	5,8	6,6667	36,3	26,4	45	1,4708	0,9	3871,4924
2016	2	18	6,6	7,3333	35,4	24,9	58	0,9792	0	3182,0485
2016	2	19	8,5	5,3333	37,3	25,5	48	1,0833	0	4293,4084
2016	2	20	1,1	7,3333	34	26,8	52	1,1125	0	2951,0554
2016	2	21	0,6	8	33,8	27,4	54	1,8417	2,4	1918,6574
2016	2	22	3,7	7,3333	34,6	24,2	72	1,0417	0	2923,949
2016	2	23	8	5,3333	36,8	24,2	55	1,5167	0	3495,5392
2016	2	24	7,2	4,6667	37,2	25,2	50	1,0292	0	5361,1625
2016	2	25	2,8	8	34,2	26,8	67	1,3875	0,3	2370,0369
2016	2	26	1,8	6	34	25	66	0,9167	0	3909,2055
2016	2	27	8,2	4	36,6	25,1	52	1,4542	0	3444,8622
2016	2	28	4,9	6,6667	36,2	26	54	1,4458	0	5273,9508

2016	2	29	5,4	6	35,8	27,6	51	1,425	0,9	4087,1646
2016	3	1	1,5	6,6667	34,4	27,8	61	1,7375	7,5	3363,5432
2016	3	2	0	7,3333	30,4	25	90	0,2958	13,1	1525,0262
2016	3	3	3,6	7,3333	32,4	24,5	70	1,0083	0,5	2757,7754
2016	3	4	0,1	8	30,8	24,7	87	0,5417	14,1	2350,0018
2016	3	5	5	5,3333	33,4	23,2	72	0,6833	4	4094,2358
2016	3	6	5	7,3333	34	24	61	1,4083	24,2	4266,3021
2016	3	7	4,4	4	34,3	23,2	70	1,6	6,5	3969,3109
2016	3	8	4,3	5,3333	31,2	23,2	73	1,4083	1,1	3744,2104
2016	3	9	4,8	5,3333	33,8	23,6	73	0,75	0,6	3909,2055
2016	3	10	5	3,3333	35	24,9	62	1,0417	0	3883,2777
2016	3	11	5,8	4,6667	35	25,3	61	1,4417	0	3589,8222
2016	3	12	4,4	6	34,3	25,5	64	1,1042	0	3682,9265
2016	3	13	0	8	32,2	24,8	78	1,7417	0	2169,6857
2016	3	14	5,2	7,3333	33,6	23,4	66	1	4,2	3422,47
2016	3	15	0,1	5,3333	30,2	23,8	78	0,7042	0	2212,113
2016	3	16	2,7	7,3333	35,6	24,6	62	1,0917	0	2271,0398
2016	3	17	5,3	8	34,7	25,1	51	1,9583	0	3569,787
2016	3	18	5,8	5,3333	34,8	24,8	60	0,85	0	3843,2075
2016	3	19	3,9	6,6667	35,5	24,8	53	1,0708	0	3700,6046
2016	3	20	7,5	5,3333	36,9	26	48	2,025	3,8	4740,0738
2016	3	21	2,4	6	34,4	24,2	70	1,6208	0	2786,0603
2016	3	22	3,2	8	33,5	24,8	60	1,3667	0	2637,5647
2016	3	23	2,7	6	31,3	25,2	69	2,0167	0,1	2346,4662
2016	3	24	10	2	37,4	24,2	48	1,8458	0	3566,2514
2016	3	25	9,8	3,3333	38,1	24,3	45	1,0708	0	883,90237
2016	3	26	6,4	3,3333	36,6	24,4	49	1,1917	0	3303,4378
2016	3	27	6	4,6667	36,9	24,2	48	1,75	0	4309,908
2016	3	28	5,5	6,6667	36,8	25,6	56	1,7875	119,8	3950,4543
2016	3	29	1,3	5,3333	33,9	23	78	0,8708	0,4	4308,7294
2016	3	30	2,6	6	34,4	23,4	66	0,9208	0,3	4332,3001
2016	3	31	0,9	7,3333	31	24,2	79	0,8583	0,7	2094,2593
2016	4	1	6,1	5,3333	34,5	24,3	65	1,0125	13,4	3032,3744
2016	4	2	0,9	8	32,5	24	88	1,025	0,2	2142,5793
2016	4	3	4,7	5,3333	34,4	23,7	69	0,825	27	4262,7665
2016	4	4	3,2	7,3333	30,3	22,2	83	1,0542	3,7	2682,3491
2016	4	5	6,4	6	34	22,2	67	0,7375	15	3741,8534
2016	4	6	4,2	6,6667	32,1	23	74	0,7333	0	2934,5559

2016	4	7	5,5	6,6667	34,9	23,7	63	0,8583	0	2859,1295
2016	4	8	4,2	6	34,3	24,8	61	0,7708	1,2	3383,5783
2016	4	9	0,4	7,3333	30,8	24,7	75	1,2542	0	1875,0516
2016	4	10	0,3	8	30,7	24,3	71	0,9875	0,1	2555,0671
2016	4	11	4,1	7,3333	34,6	24,6	68	1,0333	64	3763,067
2016	4	12	1,1	8	30,3	21,7	91	0,95	2,2	2161,4359
2016	4	13	2,8	7,3333	29,8	21,8	79	0,5167	1,8	2800,2027
2016	4	14	7,9	6,6667	33,6	23,2	70	0,7	0	3594,5363
2016	4	15	6,6	7,3333	32,8	23,6	68	0,9208	0	3540,3236
2016	4	16	9,7	5,3333	36,3	25,2	61	1,3167	7,1	4074,2007
2016	4	17	3,1	7,3333	33	23,5	77	0,7292	0,9	2809,631
2016	4	18	8,8	5,3333	34,6	23,5	69	0,775	0	4717,6816
2016	4	19	10,4	4,6667	36	23,8	58	1,1875	0	5715,902
2016	4	20	5,7	8	35,5	24,9	62	1,4417	12,5	3190,2983
2016	4	21	6,1	5,3333	34,6	23,3	67	0,7792	0	4786,0367
2016	4	22	0	8	31,9	23,6	86	1,2583	4,4	841,47506
2016	4	23	5,1	5,3333	32,7	22,3	73	0,5917	0	4157,8767
2016	4	24	0,6	7,3333	30,3	22,6	82	0,5667	0,6	3899,7773
2016	4	25	8,8	6	33,8	23,8	64	0,95	0	4269,8377
2016	4	26	6,1	7,3333	33,8	23,8	68	0,975	1,6	4769,5372
2016	4	27	5,8	7,3333	32,2	23,4	76	1,9125	25,5	3752,4602
2016	4	28	0	8	29,9	23,2	85	1,0583	3,1	1991,7267
2016	4	29	2,2	7,3333	32	23,4	70	0,7625	0,6	4248,6241
2016	4	30	2,5	8	33,1	23,6	60	1,8833	0	4268,6592
2016	5	1	3	7,3333	33,5	24,2	64	1,0417	0	4456,0465
2016	5	2	6,4	6,6667	35,4	24	59	1,1125	0	5629,8688
2016	5	3	7,1	6,6667	34,2	24,1	70	1,55	1	4121,3421
2016	5	4	8,6	6,6667	34,8	23,6	68	0,6583	0	3192,6554
2016	5	5	9,7	5,3333	34,9	23,7	58	2,2917	0	5741,8298
2016	5	6	6,4	7,3333	35,6	24,7	65	2,0083	16,6	3118,4076
2016	5	7	4,6	6,6667	32,2	23,1	78	0,6083	14,3	5105,4201
2016	5	8	6,4	6,6667	31,7	22,2	76	1,0958	16,5	3422,47
2016	5	9	5	7,3333	31,8	22,3	80	1,1125	0	3908,027
2016	5	10	4,5	8	31	22,5	76	1,375	0	4195,5899
2016	5	11	6,8	6	34	24	71	0,9167	0	5715,902
2016	5	12	7,6	7,3333	33,6	23,4	65	1,1167	0	3633,428
2016	5	13	2,9	7,3333	32,4	23,8	73	0,675	0	2160,2574
2016	5	14	4,4	6,6667	34,1	23,6	58	1,9375	0,3	2481,9979

2016	5	15	9,3	6,6667	34,2	23,8	60	2,025	0	4150,8055
2016	5	16	4	6	33,6	23,8	60	1,9375	0	3507,3246
2016	5	17	6,1	5,3333	34,9	24,2	67	1,9958	7,1	5143,1333
2016	5	18	3,5	8	33,2	24,5	60	1,5583	0	4602,185
2016	5	19	3,6	6	33	25	67	1,1167	0	4430,1187
2016	5	20	4,8	6,6667	34,5	25	57	1,0625	0	2841,4515
2016	5	21	4,9	6	32,4	25,2	60	2,8208	0,1	3402,4349
2016	5	22	9,6	7,3333	36,4	25,5	47	2,275	0	3162,0134
2016	5	23	4,1	7,3333	34,5	25,5	51	2,6167	3,4	3140,7998
2016	5	24	1,2	8	31,4	23,1	81	1,9208	0,4	2549,1744
2016	5	25	8,4	5,3333	35,8	22,2	59	1,8292	0	4608,0777
2016	5	26	4,4	7,3333	32,1	22,4	68	1,05	0	2909,8066
2016	5	27	7	5,3333	34,4	22,8	62	1,9667	3,6	4338,1928
2016	5	28	0,3	8	28,1	23	84	2,2625	2,7	2397,1432
2016	5	29	3,9	7,3333	32,4	23,2	68	0,8208	0,1	3981,0963
2016	5	30	7,5	5,3333	35,6	23,2	67	0,9333	6	5924,503
2016	5	31	2,1	8	30,3	23,5	86	2,1208	0,9	3600,429
2016	6	1	4,3	6	32,3	22	72	0,7208	0	4265,1236
2016	6	2	4,8	6	33,4	22,4	62	0,9625	0	3437,791
2016	6	3	3,6	7,3333	33,3	22,6	68	0,6417	12,3	3620,4641
2016	6	4	9,1	5,3333	32,6	21,6	66	0,9	0	3506,1461
2016	6	5	11	3,3333	35,3	21,6	60	0,9792	0	2327,6096
2016	6	6	1,9	7,3333	33,1	23,5	67	0,525	0	3295,188
2016	6	7	5,3	7,3333	31,6	22,9	70	0,9042	0,6	4253,3382
2016	6	8	7,5	5,3333	34	23	60	2,1	0	3984,6319
2016	6	9	7,2	6,6667	33,4	23,6	58	2	0,7	4969,8884
2016	6	10	4,3	6	33,9	23,5	66	1,075	0,1	4179,0904
2016	6	11	9,4	4,6667	34	23,7	52	2,3958	0	3536,788
2016	6	12	6,8	5,3333	33	23,8	59	1,8625	0	3435,4339
2016	6	13	0	7,3333	29,7	23,8	70	3,0667	0,9	3387,1139
2016	6	14	6,2	6,6667	35,1	23,5	54	2,475	0	4543,2582
2016	6	15	6,3	5,3333	33,4	23,8	50	2,6958	3	4965,1742
2016	6	16	9,7	6	32,3	21,6	61	2,8417	0	4175,5548
2016	6	17	7,3	6	33,5	22,3	48	1,9292	0,1	4207,3753
2016	6	18	2,6	7,3333	32,5	23,4	61	2,0625	0,5	3037,0885
2016	6	19	4,1	7,3333	33	23,3	60	3,6833	0,9	2923,949
2016	6	20	3,3	7,3333	31,2	22,2	65	2,8792	0	3796,066
2016	6	21	3,7	7,3333	32,8	22,2	56	2,3042	0	2809,631

2016	6	22	9,2	4,6667	34,7	24,3	46	2,5375	0	3668,7841
2016	6	23	4,8	7,3333	32,8	24,6	55	1,7042	1,1	3496,7178
2016	6	24	5,6	6,6667	34	24,7	57	2,2708	0,1	4246,267
2016	6	25	7,7	6,6667	35,1	23,8	49	2,2875	0,7	4728,2884
2016	6	26	5,3	6	32,2	22,7	62	2,9292	0	3745,389
2016	6	27	9,8	6	35,2	22,8	46	2,3333	0	3427,1841
2016	6	28	5,8	6,6667	34,3	24,8	53	3,3875	0	3294,0095
2016	6	29	7,8	6,6667	35,3	25,2	50	3,1958	0	3145,5139
2016	6	30	2,8	8	33,6	24,5	53	2,9	0	1721,8418
2016	7	1	2	8	32,6	24,2	55	2,2708	0	2539,7461
2016	7	2	6,4	8	33,3	23,2	59	3,1125	0	4928,6396
2016	7	3	4,3	8	33,5	23,6	53	2,1208	0	4240,3743
2016	7	4	1,6	8	32,6	24,4	50	2,1708	0	2988,7685
2016	7	5	6,1	7,3333	33,6	24,7	50	1,775	0	4144,9128
2016	7	6	1,3	8	31,8	23,6	79	1,4042	7,1	2312,2886
2016	7	7	6,3	6	35,2	22,1	55	2,2375	0	3649,9275
2016	7	8	10,5	5,3333	34,2	23,5	47	2,7625	0	3686,4622
2016	7	9	8,4	6	35,9	23,1	45	2,3	0	3726,5324
2016	7	10	7	6	34,7	24,2	48	3,2167	0	4678,7899
2016	7	11	6,3	7,3333	35,6	24,6	57	2,3417	0,7	4716,503
2016	7	12	9,5	6,6667	35,7	21,4	54	1,4458	0	4565,6504
2016	7	13	6,8	6,6667	36,1	21,9	48	1,1208	0	5200,8815
2016	7	14	7,6	7,3333	36,4	24,2	54	1,8875	0	4361,7636
2016	7	15	7	4,6667	35,9	22,6	49	1,1875	0	4302,8367
2016	7	16	4,6	8	33,8	23,2	65	1,2583	0,2	3582,7509
2016	7	17	5,5	7,3333	33,7	22,3	58	1,5333	0,8	3147,871
2016	7	18	0,9	8	30,2	22,4	68	2,475	0,3	3527,3597
2016	7	19	4,6	6	33,7	21,6	53	1,15	3,3	5107,7772
2016	7	20	4,2	8	32	21,8	64	2,1083	0	3651,1061
2016	7	21	3,6	8	31,8	21,8	56	3,0583	0	3289,2954
2016	7	22	0,8	7,3333	28,8	23,8	60	2,9583	0,1	3075,9802
2016	7	23	5,7	5,3333	33,9	21	50	1,6542	0,3	5486,0874
2016	7	24	6,5	6,6667	35,5	21,5	50	1,3208	0	4327,586
2016	7	25	6	7,3333	32,4	23,2	55	2,6542	0	4493,7596
2016	7	26	9,3	3,3333	36,2	22,4	48	2,3958	0	4368,8348
2016	7	27	1,3	6,6667	32,6	22,8	63	2,2667	0	1529,7404
2016	7	28	5	7,3333	33,2	22,6	50	3,25	0	2136,6867
2016	7	29	4,3	7,3333	33,6	23,6	50	3,7208	0	1334,1033

2016	7	30	6,1	5,3333	33,3	24,2	47	3,1875	0	2457,2486
2016	7	31	5,3	6	33,7	24,6	46	3,5458	0	6058,8561
2016	8	1	0,8	7,3333	32,2	24,7	41	3,2417	0	3362,3646
2016	8	2	2,2	7,3333	32,5	24,8	49	0,675	0	2833,2017
2016	8	3	3,7	8	33,8	24,8	43	0	0	3103,0866
2016	8	4	3,1	7,3333	33	25,2	49	0	0	3165,549
2016	8	5	8	7,3333	36	23,6	41	1,3667	0	4749,5021
2016	8	6	3,7	7,3333	35,3	24,2	39	2,0875	0	3961,0612
2016	8	7	4,7	7,3333	33,7	25,8	50	2,8583	0	3830,2436
2016	8	8	2	6	32,1	24,7	53	1,7333	1,4	2306,3959
2016	8	9	6,7	7,3333	33,9	22,6	54	2,7917	0,3	3541,5022
2016	8	10	2,5	7,3333	33,8	22,4	50	2,4542	0,3	2593,9588
2016	8	11	2,8	5,3333	34	24	52	2,9	0	1271,6409
2016	8	12	8,9	6	35,6	23,5	46	2,1875	0	3718,2826
2016	8	13	3,6	7,3333	34,1	23,6	47	1,9167	0	4543,2582
2016	8	14	7,6	6	36,4	24,5	41	2,625	0	3171,4417
2016	8	15	6,9	6,6667	35,9	23,8	45	1,8583	0	4121,3421
2016	8	16	8,1	7,3333	35,5	25,1	43	1,975	0,4	2791,953
2016	8	17	2,8	7,3333	33,7	25,2	65	1,2958	1,6	2578,6378
2016	8	18	4,7	6,6667	34	23,5	60	1,375	0	3799,6017
2016	8	19	5,9	6	36,1	23,3	45	1,2	0	2940,4486
2016	8	20	9	6	36,1	25	40	2,65	0	2472,5696
2016	8	21	5,9	7,3333	33	24,8	48	3,4917	4,9	1475,5277
2016	8	22	7,4	6	32,2	21,4	59	4,5625	0	3278,6885
2016	8	23	11	2	36,8	22	40	2,7125	0	3565,0729
2016	8	24	0,9	6,6667	34,4	24,5	39	2,1375	0	0
2016	8	25	8,1	5,3333	36,8	22,7	36	3,6208	0	0
2016	8	26	4,2	6	34,6	24,4	40	2,9375	0	3618,107
2016	8	27	6,5	6,6667	35,2	25,6	42	2,0708	0	4822,5713
2016	8	28	6,7	6,6667	35,9	25	44	1,4167	0	4286,3372
2016	8	29	6,6	7,3333	37,2	24,7	44	1,5417	0,3	4084,8075
2016	8	30	3,2	6	33,6	24,6	60	1,475	0,3	2223,8984
2016	8	31	2,2	8	32,5	22,3	58	1,2083	1,1	1885,6584
2016	9	1	5,7	6,6667	31,7	22,2	63	1,9208	0,2	3622,8212
2016	9	2	9,1	4	35,8	22	50	1,1167	0	5245,6659
2016	9	3	9,8	4,6667	36,8	22,2	46	1,2625	0,9	3225,6544
2016	9	4	4,5	8	35	23,6	55	1,7542	0	3659,3558
2016	9	5	6,9	8	35,7	24,2	45	1,825	4,7	3978,7392

2016	9	6	6,4	7,3333	34,4	23	72	2,7042	0,9	4697,6465
2016	9	7	0,2	7,3333	30,4	23,6	67	1,5917	0,8	492,62825
2016	9	8	10,3	6	36,8	20,3	52	1,8542	0	4625,7557
2016	9	9	6,6	6	36,6	20,6	42	3,3583	0	4081,2719
2016	9	10	5,2	8	32,9	26,2	63	3,95	0,1	2769,5608
2016	9	11	4,5	7,3333	33,6	24,9	51	3,825	0,1	4690,5752
2016	9	12	4,1	8	35,5	25,1	43	2,1	0	2992,3042
2016	9	13	6,4	6	35,8	25,5	51	2,2833	0,7	3935,1334
2016	9	14	0,2	8	31,4	22,8	89	1,325	64,3	1930,4428
2016	9	15	6,1	6,6667	33,5	20,8	64	0,7208	0	5108,9557
2016	9	16	10,8	3,3333	36,1	22	51	0,8875	0	6255,6717
2016	9	17	10,1	3,3333	37,1	22,8	44	1,7292	0	5229,1664
2016	9	18	3,1	8	34,4	24	45	1,35	0	4278,0875
2016	9	19	2	8	32,1	26	58	2,4083	0,3	2887,4144
2016	9	20	8,1	6,6667	36	24,4	44	3,7708	0	4050,6299
2016	9	21	5,5	5,3333	35,3	25,2	43	2,8	0,1	4993,4591
2016	9	22	4,1	6,6667	35,2	22,7	48	0,7083	0	4494,9382
2016	9	23	8,3	7,3333	36,5	23,7	57	1,3875	0,2	2164,9715
2016	9	24	0,2	8	30	24,3	64	1,9833	0,5	2793,1315
2016	9	25	3,8	7,3333	32,9	23	56	1,6208	0	4535,0084
2016	9	26	7,9	6,6667	35,9	23	46	2,1958	0	4150,8055
2016	9	27	9,6	4,6667	36,3	24,6	40	1,3875	0	4530,2943
2016	9	28	2	8	33,2	25,4	58	1,7042	0	2695,313
2016	9	29	9,2	6,6667	36,5	22,1	50	1,0542	14,1	4043,5587
2016	9	30	6	6,6667	33,7	22,4	69	0,8708	6,3	5085,385

Anexo B. Tabla de resultados y convenciones del modelo neuronal previo

CONVENCIONES	
Color	Significado
	Modelos de buen rendimiento y precisos
	Modelos de rendimiento regular
	Modelos de mal rendimiento

Submodelo de tres variables de entrada: horas de brillo solar, nubosidad, humedad relativa

Capa Oculta		Capa de Entrada	Coeficiente de Determinación (R ²)			
Número de neuronas		Número de entradas	Entrenamiento		Prueba	
Capa 1	Capa 2	#	Mínimo	Máximo	Mínimo	Máximo
10	0	3	0,9938	0,9939	0,0145	0,9371
20	0	3	0,9938	0,9938	0,4119	0,7177
30	0	3	0,9938	0,9944	0,0897	0,7918
40	0	3	0,9938	0,9943	0,0316	0,8444
50	0	3	0,9938	0,9956	0,0415	0,8010
60	0	3	0,9939	0,9946	0,0378	0,8935
70	0	3	0,9940	0,9943	0,3987	0,6962
80	0	3	0,9938	0,9948	0,0142	0,8534
90	0	3	0,9939	0,9952	0,0704	0,8843
100	0	3	0,9938	0,9944	0,3318	0,6843
10	10	3	0,9938	0,9939	0,0512	0,8905
20	10	3	0,9938	0,9939	0,3844	0,8195
30	10	3	0,9938	0,9951	0,2182	0,7773
40	10	3	0,9938	0,9943	0,5069	0,8904
50	10	3	0,9938	0,9941	0,6633	0,8543
60	10	3	0,9940	0,9949	0,2916	0,8297
70	10	3	0,9939	0,9949	0,6736	0,8474
80	10	3	0,9939	0,9951	0,4936	0,8601
90	10	3	0,9938	0,9957	0,5883	0,8773
100	10	3	0,9942	0,9962	0,5984	0,8928
10	20	3	0,9938	0,9941	0,2137	0,7944
20	20	3	0,9938	0,9939	0,5844	0,8944
30	20	3	0,9938	0,9942	0,4299	0,7016
40	20	3	0,9938	0,9953	0,4348	0,9220
50	20	3	0,9938	0,9945	0,2976	0,9135
60	20	3	0,9938	0,9961	0,6315	0,8754

70	20	3	0,9942	0,9953	0,0166	0,8518
80	20	3	0,9939	0,9955	0,3643	0,8484
90	20	3	0,9938	0,9951	0,7192	0,8680
100	20	3	0,9938	0,9948	0,6250	0,9265
10	30	3	0,9938	0,9940	0,2665	0,8196
20	30	3	0,9938	0,9941	0,0655	0,9098
30	30	3	0,9938	0,9940	0,7626	0,9529
40	30	3	0,9938	0,9941	0,1453	0,9321
50	30	3	0,9943	0,9956	0,0601	0,8273
60	30	3	0,9939	0,9944	0,6511	0,8938
70	30	3	0,9941	0,9954	0,0305	0,8847
80	30	3	0,9946	0,9957	0,1276	0,8658
90	30	3	0,9946	0,9956	0,4352	0,8777
100	30	3	0,9945	0,9960	0,4681	0,7595
10	40	3	0,9938	0,9940	0,7044	0,8769
20	40	3	0,9938	0,9946	0,4509	0,8453
30	40	3	0,9938	0,9946	0,0551	0,7482
40	40	3	0,9940	0,9961	0,4263	0,9055
50	40	3	0,9938	0,9955	0,0773	0,8674
60	40	3	0,9941	0,9958	0,0438	0,5569
70	40	3	0,9936	0,9952	0,2166	0,7603
80	40	3	0,9950	0,9964	0,6169	0,6535
90	40	3	0,9941	0,9958	0,0147	0,7277
100	40	3	0,9951	0,9956	0,2083	0,8650
10	50	3	0,9938	0,9954	0,6201	0,9124
20	50	3	0,9938	0,9938	0,4903	0,7176
30	50	3	0,9939	0,9953	0,0299	0,9043
40	50	3	0,9938	0,9954	0,5392	0,8586
50	50	3	0,9943	0,9960	0,0293	0,8327
60	50	3	0,9952	0,9962	0,3488	0,5607
70	50	3	0,9951	0,9954	0,5115	0,8369
80	50	3	0,9942	0,9957	0,0293	0,6944
90	50	3	0,9943	0,9950	0,0182	0,6716
100	50	3	0,9946	0,9961	0,7037	0,8990
10	60	3	0,9939	0,9952	0,3711	0,8670
20	60	3	0,9938	0,9944	0,2943	0,8157
30	60	3	0,9938	0,9948	0,0196	0,8687
40	60	3	0,9939	0,9952	0,5200	0,9047
50	60	3	0,9940	0,9954	0,0140	0,9197
60	60	3	0,9948	0,9958	0,4677	0,9129

70	60	3	0,9950	0,9954	0,0245	0,4736
80	60	3	0,9940	0,9957	0,5748	0,8061
90	60	3	0,9944	0,9957	0,0274	0,7221
100	60	3	0,9943	0,9963	0,1343	0,6198
10	70	3	0,9938	0,9943	0,2688	0,9264
20	70	3	0,9938	0,9941	0,5849	0,8485
30	70	3	0,9939	0,9944	0,1011	0,6937
40	70	3	0,9939	0,9952	0,0875	0,9087
50	70	3	0,9939	0,9955	0,0516	0,8428
60	70	3	0,9938	0,9955	0,0198	0,8896
70	70	3	0,9946	0,9957	0,4052	0,8545
80	70	3	0,9941	0,9949	0,0341	0,8402
90	70	3	0,9939	0,9953	0,4528	0,8840
100	70	3	0,9948	0,9959	0,4136	0,7060
10	80	3	0,9938	0,9944	0,0776	0,8302
20	80	3	0,9938	0,9955	0,4666	0,9307
30	80	3	0,9942	0,9957	0,0173	0,6758
40	80	3	0,9940	0,9959	0,0117	0,9071
50	80	3	0,9942	0,9961	0,2465	0,7116
60	80	3	0,9942	0,9953	0,0811	0,8150
70	80	3	0,9940	0,9949	0,0301	0,5569
80	80	3	0,9949	0,9952	0,6068	0,9076
90	80	3	0,9946	0,9957	0,5285	0,7352
100	80	3	0,9942	0,9953	0,2545	0,5558
10	90	3	0,9938	0,9942	0,2740	0,9192
20	90	3	0,9938	0,9940	0,3909	0,8349
30	90	3	0,9938	0,9949	0,0311	0,7978
40	90	3	0,9940	0,9959	0,0243	0,8373
50	90	3	0,9952	0,9960	0,0503	0,5353
60	90	3	0,9942	0,9955	0,0511	0,7290
70	90	3	0,9956	0,9958	0,3610	0,5732
80	90	3	0,9952	0,9959	0,4292	0,5988
90	90	3	0,9945	0,9960	0,2363	0,8693
100	90	3	0,9947	0,9951	0,4129	0,9021
10	100	3	0,9939	0,9946	0,0577	0,5808
20	100	3	0,9939	0,9949	0,6576	0,8882
30	100	3	0,9940	0,9951	0,0259	0,9391
40	100	3	0,9939	0,9959	0,6491	0,7973
50	100	3	0,9951	0,9953	0,0415	0,8635
60	100	3	0,9947	0,9954	0,0390	0,8080

70	100	3	0,9943	0,9954	0,0389	0,5868
80	100	3	0,9942	0,9952	0,4406	0,8056
90	100	3	0,9952	0,9956	0,3403	0,8167
100	100	3	0,9946	0,9950	0,3359	0,5721

Submodelo de cinco variables de entrada: horas de brillo solar, nubosidad, temperatura máxima

Capa Oculta		Capa de Entrada	Coeficiente de Determinación (R ²)			
Número de neuronas		Número de entradas	Entrenamiento		Prueba	
Capa 1	Capa 2	#	Mínimo	Máximo	Mínimo	Máximo
10	0	5	0,9938	0,9939	0,8205	0,9221
20	0	5	0,9938	0,9941	0,6307	0,9219
30	0	5	0,9938	0,9942	0,0585	0,8968
40	0	5	0,9938	0,9943	0,3381	0,8854
50	0	5	0,9939	0,9946	0,0414	0,9060
60	0	5	0,9938	0,9942	0,3814	0,7848
70	0	5	0,9938	0,9940	0,5055	0,8620
80	0	5	0,9938	0,9945	0,3224	0,8122
90	0	5	0,9938	0,9945	0,0347	0,8949
100	0	5	0,9941	0,9956	0,3234	0,8791
10	10	5	0,9938	0,9940	0,8338	0,9289
20	10	5	0,9938	0,9943	0,8057	0,9047
30	10	5	0,9938	0,994	0,8319	0,9255
40	10	5	0,9938	0,9939	0,8971	0,9234
50	10	5	0,9938	0,9942	0,7135	0,9200
60	10	5	0,9938	0,9945	0,8384	0,9462
70	10	5	0,9938	0,9941	0,8163	0,9459
80	10	5	0,9938	0,9948	0,8259	0,9263
90	10	5	0,9939	0,9941	0,7544	0,9391
100	10	5	0,9939	0,9945	0,7965	0,9203
10	20	5	0,9938	0,9942	0,8136	0,8801
20	20	5	0,9938	0,9943	0,7199	0,9290
30	20	5	0,9938	0,9950	0,3449	0,8836
40	20	5	0,9938	0,9945	0,7628	0,9002
50	20	5	0,9938	0,9945	0,7393	0,9286
60	20	5	0,9941	0,9956	0,6199	0,9193
70	20	5	0,9938	0,9948	0,8464	0,9245
80	20	5	0,9939	0,9948	0,8794	0,9427

90	20	5	0,9938	0,9954	0,8231	0,9398
100	20	5	0,9939	0,9948	0,1094	0,9015
10	30	5	0,9938	0,9940	0,7767	0,8718
20	30	5	0,9939	0,9951	0,1540	0,9312
30	30	5	0,9938	0,9948	0,3376	0,9279
40	30	5	0,9939	0,9943	0,6446	0,9299
50	30	5	0,9939	0,9945	0,7213	0,8889
60	30	5	0,9938	0,9955	0,5576	0,9247
70	30	5	0,9938	0,9947	0,6312	0,8994
80	30	5	0,9939	0,9953	0,4275	0,8026
90	30	5	0,9939	0,9958	0,8446	0,8965
100	30	5	0,9941	0,9948	0,5888	0,9373
10	40	5	0,9938	0,9944	0,6229	0,9408
20	40	5	0,9938	0,9943	0,1231	0,8969
30	40	5	0,9939	0,9945	0,7281	0,8520
40	40	5	0,9938	0,9953	0,0709	0,9116
50	40	5	0,9939	0,9954	0,5759	0,9271
60	40	5	0,9939	0,9952	0,1413	0,9655
70	40	5	0,9939	0,9940	0,0312	0,8385
80	40	5	0,9950	0,9952	0,7971	0,9406
90	40	5	0,9941	0,9945	0,6770	0,9083
100	40	5	0,9939	0,9948	0,4071	0,7873
10	50	5	0,9938	0,9942	0,0123	0,8842
20	50	5	0,9938	0,9948	0,4957	0,8649
30	50	5	0,9938	0,9948	0,0507	0,8987
40	50	5	0,9940	0,9952	0,2709	0,9096
50	50	5	0,9939	0,9958	0,3515	0,8305
60	50	5	0,9939	0,9945	0,2324	0,9275
70	50	5	0,9944	0,9946	0,5079	0,9154
80	50	5	0,9940	0,9955	0,3987	0,6833
90	50	5	0,9942	0,9953	0,0347	0,8529
100	50	5	0,9944	0,9951	0,2624	0,6158
10	60	5	0,9938	0,9942	0,5456	0,9165
20	60	5	0,9938	0,9947	0,1199	0,8494
30	60	5	0,9939	0,9950	0,5588	0,8660
40	60	5	0,9938	0,9946	0,0284	0,8074
50	60	5	0,9939	0,9954	0,5130	0,7411
60	60	5	0,9939	0,9945	0,4916	0,8621
70	60	5	0,9943	0,9950	0,7832	0,9118
80	60	5	0,9945	0,9949	0,4761	0,8864

90	60	5	0,9947	0,9953	0,2264	0,9393
100	60	5	0,9939	0,9949	0,0701	0,8484
10	70	5	0,9938	0,9941	0,6772	0,7312
20	70	5	0,9938	0,9942	0,2124	0,7631
30	70	5	0,9939	0,9942	0,0012	0,7993
40	70	5	0,9939	0,9941	0,7124	0,7253
50	70	5	0,9938	0,9945	0,6431	0,7661
60	70	5	0,9941	0,995	0,1072	0,5694
70	70	5	0,9955	0,9958	0,7248	0,7871
80	70	5	0,9949	0,9951	0,6635	0,7267
90	70	5	0,9949	0,9952	0,0852	0,6243
100	70	5	0,9944	0,9946	0,3078	0,6485
10	80	5	0,9938	0,9942	0,1720	0,7720
20	80	5	0,9938	0,9950	0,4738	0,8965
30	80	5	0,9938	0,9949	0,1519	0,8584
40	80	5	0,9945	0,9948	0,3860	0,8259
50	80	5	0,9941	0,9945	0,6338	0,9014
60	80	5	0,9938	0,9949	0,6121	0,6909
70	80	5	0,9938	0,9946	0,6550	0,8182
80	80	5	0,9945	0,9958	0,0128	0,6628
90	80	5	0,9947	0,9952	0,1348	0,2383
100	80	5	0,9954	0,9955	0,5332	0,5898
10	90	5	0,9938	0,9939	0,2853	0,7549
20	90	5	0,9938	0,9943	0,3738	0,7232
30	90	5	0,9945	0,9952	0,6342	0,8799
40	90	5	0,9944	0,9949	0,2027	0,8066
50	90	5	0,9938	0,9945	0,0612	0,8853
60	90	5	0,9949	0,9949	0,0756	0,2109
70	90	5	0,9943	0,9946	0,5905	0,8623
80	90	5	0,9941	0,9948	0,0557	0,3648
90	90	5	0,9959	0,9960	0,5431	0,7537
100	90	5	0,9941	0,9956	0,092	0,6826
10	100	5	0,9939	0,9950	0,6404	0,8501
20	100	5	0,9938	0,9951	0,1369	0,2808
30	100	5	0,9943	0,9951	0,2877	0,7817
40	100	5	0,9940	0,9942	0,6110	0,7537
50	100	5	0,9945	0,9948	0,4102	0,8875
60	100	5	0,9951	0,9954	0,1324	0,5608
70	100	5	0,9951	0,9952	0,0392	0,1044
80	100	5	0,9947	0,9949	0,2518	0,7305

90	100	5	0,9951	0,9960	0,6009	0,8067
100	100	5	0,9954	0,9959	0,2233	0,6200

Submodelo de siete variables de entrada: horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento y precipitaciones

Capa Oculta		Capa de Entrada	Coeficiente de Determinación (R ²)			
Número de neuronas		Número de entradas	Entrenamiento		Prueba	
Capa 1	Capa 2	#	Mínimo	Máximo	Mínimo	Máximo
10	0	7	0,9938	0,9940	0,7727	0,9402
20	0	7	0,9938	0,9939	0,3067	0,4665
30	0	7	0,9938	0,9944	0,3040	0,8803
40	0	7	0,9938	0,9946	0,0459	0,8815
50	0	7	0,9938	0,9951	0,0107	0,8773
60	0	7	0,9940	0,9954	0,2913	0,8856
70	0	7	0,9938	0,9955	0,0460	0,7253
80	0	7	0,9941	0,9955	0,1924	0,6468
90	0	7	0,9940	0,9946	0,0182	0,5668
100	0	7	0,9946	0,9955	0,0049	0,7330
10	10	7	0,9938	0,9941	0,5001	0,9013
20	10	7	0,9938	0,9949	0,7005	0,9444
30	10	7	0,9939	0,9956	0,7523	0,9393
40	10	7	0,9939	0,9951	0,6134	0,9092
50	10	7	0,9943	0,995	0,8031	0,9183
60	10	7	0,9939	0,9955	0,8083	0,9372
70	10	7	0,9939	0,9947	0,6374	0,7374
80	10	7	0,9941	0,9946	0,6797	0,9169
90	10	7	0,9939	0,9951	0,7210	0,9368
100	10	7	0,9939	0,9953	0,8104	0,8845
10	20	7	0,9939	0,9954	0,7718	0,8958
20	20	7	0,9938	0,9944	0,1240	0,9142
30	20	7	0,9938	0,9947	0,3873	0,9170
40	20	7	0,9940	0,9949	0,0993	0,9190
50	20	7	0,9940	0,9947	0,7647	0,9272
60	20	7	0,9944	0,9953	0,0429	0,8241
70	20	7	0,9942	0,9952	0,6645	0,9316
80	20	7	0,9945	0,9953	0,6675	0,8661
90	20	7	0,9946	0,9956	0,7644	0,8346
100	20	7	0,9938	0,9950	0,2292	0,9093

10	30	7	0,9939	0,9945	0,3183	0,8910
20	30	7	0,9944	0,9953	0,3844	0,8126
30	30	7	0,9939	0,9943	0,4463	0,8819
40	30	7	0,9939	0,9957	0,3771	0,8207
50	30	7	0,9941	0,9955	0,6346	0,8655
60	30	7	0,9940	0,9952	0,1285	0,9288
70	30	7	0,9941	0,9954	0,1905	0,8147
80	30	7	0,9946	0,9950	0,5456	0,8628
90	30	7	0,9939	0,9959	0,5620	0,8148
100	30	7	0,9940	0,9959	0,8188	0,8575
10	40	7	0,9940	0,9947	0,3891	0,9337
20	40	7	0,9941	0,9952	0,3829	0,8857
30	40	7	0,9939	0,9953	0,0185	0,7704
40	40	7	0,9942	0,9949	0,1786	0,8783
50	40	7	0,9940	0,9955	0,1995	0,9143
60	40	7	0,9939	0,9956	0,1827	0,8581
70	40	7	0,9938	0,9960	0,6712	0,9009
80	40	7	0,9941	0,9959	0,2328	0,7166
90	40	7	0,9943	0,9962	0,1128	0,8745
100	40	7	0,9939	0,9958	0,1711	0,7395
10	50	7	0,9941	0,9960	0,4883	0,9159
20	50	7	0,9940	0,9955	0,0762	0,8556
30	50	7	0,9939	0,9945	0,0069	0,8736
40	50	7	0,9945	0,9954	0,1324	0,7438
50	50	7	0,9939	0,9955	0,1498	0,8359
60	50	7	0,9938	0,9960	0,0261	0,7811
70	50	7	0,9938	0,9951	0,1262	0,7817
80	50	7	0,9942	0,9957	0,3664	0,9146
90	50	7	0,9938	0,9964	0,1214	0,8525
100	50	7	0,9939	0,9963	0,3663	0,7387
10	60	7	0,9939	0,9947	0,0187	0,9233
20	60	7	0,9942	0,9951	0,0220	0,6210
30	60	7	0,9938	0,9945	0,5676	0,8950
40	60	7	0,9942	0,9959	0,1293	0,9310
50	60	7	0,9944	0,9954	0,0145	0,8984
60	60	7	0,9945	0,9954	0,0519	0,8601
70	60	7	0,9941	0,9955	0,0739	0,6528
80	60	7	0,9945	0,9963	0,0834	0,8912
90	60	7	0,9944	0,9952	0,1386	0,9186
100	60	7	0,9941	0,9953	0,1865	0,9080

10	70	7	0,9938	0,9944	0,0072	0,7601
20	70	7	0,9938	0,9953	0,0695	0,7580
30	70	7	0,9940	0,9953	0,0840	0,7077
40	70	7	0,9939	0,9951	0,0339	0,9278
50	70	7	0,9952	0,9963	0,0121	0,9085
60	70	7	0,9947	0,9953	0,0637	0,8798
70	70	7	0,9945	0,9957	0,0583	0,8190
80	70	7	0,9939	0,9966	0,0797	0,8195
90	70	7	0,9953	0,9953	0,0644	0,9226
100	70	7	0,9946	0,9960	0,4859	0,7983
10	80	7	0,9938	0,9952	0,0336	0,9145
20	80	7	0,9939	0,9954	0,4144	0,7833
30	80	7	0,9944	0,9949	0,3812	0,7857
40	80	7	0,9938	0,9944	0,0502	0,5008
50	80	7	0,9951	0,9955	0,2201	0,6470
60	80	7	0,9948	0,9951	0,2152	0,2621
70	80	7	0,9945	0,9955	0,6335	0,8488
80	80	7	0,9949	0,9962	0,2570	0,5504
90	80	7	0,9957	0,9964	0,1183	0,3225
100	80	7	0,9948	0,9967	0,5358	0,8172
10	90	7	0,9939	0,9948	0,3731	0,9082
20	90	7	0,9940	0,9945	0,02603	0,7626
30	90	7	0,9948	0,9955	0,0087	0,8901
40	90	7	0,9939	0,9948	0,0097	0,7293
50	90	7	0,9939	0,9955	0,0141	0,7254
60	90	7	0,9940	0,9942	0,0567	0,5869
70	90	7	0,9953	0,9957	0,1605	0,7616
80	90	7	0,9947	0,9966	0,0171	0,7070
90	90	7	0,9941	0,9958	0,0939	0,3585
100	90	7	0,9942	0,9948	0,0952	0,3131
10	100	7	0,9938	0,9948	0,0315	0,9106
20	100	7	0,9941	0,9948	0,2158	0,8576
30	100	7	0,9940	0,9956	0,2539	0,5180
40	100	7	0,9941	0,9948	0,6818	0,7802
50	100	7	0,9945	0,9965	0,5719	0,6855
60	100	7	0,9946	0,9962	0,0033	0,6539
70	100	7	0,9955	0,9958	0,3844	0,7025
80	100	7	0,9940	0,9957	0,0318	0,6493
90	100	7	0,9950	0,9960	0,4496	0,8793
100	100	7	0,9939	0,9942	0,5369	0,6154

Anexo C. Tabla de reglas y convenciones del modelo difuso previo

Convenciones:

Variable	Significado
HBS	Horas de brillo solar
N	Nubosidad
TMax.	Temperatura máxima
TMin.	Temperatura mínima
HR	Humedad relativa
VV	Velocidad del viento
P	Precipitación
RS	Radiación solar

Reglas:

Regla	HBS	N	TMax.	TMin.	HR	VV	P	RS	Peso
1	Pocas	x	x	x	x	x	x	Baja	0.5
2	Medio	x	x	x	x	x	x	Media	0.5
3	Muchas	x	x	x	x	x	x	Alta	0.5
4	Demasiadas	x	x	x	x	x	x	Muy Alta	0
5	Medio	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Media	0
6	Demasiadas	Baja	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Baja	1
7	Demasiadas	Baja	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Muy Alta	1
8	Medio	Alta	Alta	Medio Baja	Alta	Baja	Baja	Alta	1
9	Muy Pocas	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Muy Baja	0.5
10	Medio	Media	Alta	Media	Alta	Media	Muy Baja	Alta	0.5
11	Medio	Alta	Muy Alta	Medio Baja	Alta	Baja	Muy Baja	Muy Alta	0.5
12	Pocas	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Alta	1
13	Muy Pocas	Media	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Alta	0.5
14	Medio	Alta	Alta	Media	Media	Alta	Muy Baja	Muy Alta	1

15	Muy Pocas	Alta	Alta	Medio Baja	Alta	Media	Muy Baja	Baja	0.5
16	Demasiadas	Baja	Alta	Baja	Alta	Baja	Muy Baja	Media	0.5
17	Muchas	Baja	Muy Alta	Media	Media	Baja	Muy Baja	Muy Alta	0.5
18	Medio	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Media	1
19	Muy Pocas	Alta	Medio Alta	Medio Baja	Alta	Media	Muy Baja	Media	1
20	Medio	Alta	Alta	Media	Media	Alta	Muy Baja	Baja	1
21	Muchas	Media	Muy Alta	Media	Media	Media	Muy Baja	Media	1
22	Medio	Media	Alta	Medio Baja	Alta	Baja	Muy Baja	Alta	1
23	Medio	Alta	Alta	Medio Baja	Alta	Media	Muy Baja	Alta	1
24	Medio	Alta	Alta	Baja	Media	Baja	Muy Baja	Muy Alta	1
25	Medio	Alta	Alta	Media	Alta	Baja	Alta	Alta	1
26	Pocas	Alta	Alta	Medio Baja	Alta	Media	Muy Baja	Alta	1
27	Demasiadas	Media	Alta	Baja	Alta	Baja	Muy Baja	Media	0.5
28	Muchas	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Media	1
29	Pocas	Alta	Alta	Media	Media	Baja	Muy Baja	Media	0
30	Medio	Media	Alta	Baja	Media	Baja	Muy Baja	Muy Alta	1
31	Demasiadas	Baja	Muy Alta	Medio Baja	Media	Media	Muy Baja	Alta	0
32	Medio	Alta	Alta	Media	Media	Baja	Muy Baja	Alta	1
33	Demasiadas	Media	Alta	Medio Baja	Media	Media	Muy Baja	Alta	0.5
34	Demasiadas	Alta	Alta	Baja	Alta	Media	Muy Baja	Alta	0
35	Demasiadas	Alta	Alta	Medio Baja	Media	Media	Muy Baja	Media	1
36	Demasiadas	Alta	Muy Alta	Baja	Media	Baja	Muy Baja	Alta	0

37	Medio	Alta	Alta	Medio Baja	Media	Alta	Muy Baja	Baja	1
38	Pocas	Alta	Alta	Media	Media	Baja	Muy Baja	Media	1
39	Pocas	Alta	Alta	Media	Alta	Baja	Muy Baja	Media	1
40	Pocas	Alta	Alta	Medio Baja	Media	Baja	Muy Baja	Alta	1
41	Medio	Alta	Muy Alta	Media	Media	Baja	Muy Baja	Alta	1
42	Demasiadas	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Alta	0
43	Medio	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Alta	0
44	Medio	Alta	Alta	Media	Media	Alta	Muy Baja	Alta	0
45	Medio	Alta	Muy Alta	Media	Media	Media	Muy Baja	Alta	0.5
46	Pocas	Alta	Alta	Media	Alta	Media	Muy Baja	Media	1
47	Medio	Media	Alta	Media	Media	Media	Muy Baja	Alta	1
48	Demasiadas	Media	Muy Alta	Media	Media	Baja	Muy Baja	Alta	1
49	Pocas	Alta	Alta	Media	Media	Media	Muy Baja	Media	1
50	Muchas	Baja	Muy Alta	Media	Media	Baja	Muy Baja	Media	1
51	Muy Pocas	Media	Alta	Media	Media	Baja	Muy Baja	Media	1
52	Muy Pocas	Alta	Alta	Media	Alta	Baja	Muy Baja	Media	1
53	Muchas	Alta	Muy Alta	Media	Media	Baja	Muy Baja	Media	0
54	Muy Pocas	Alta	Alta	Media	Alta	Baja	Muy Baja	Baja	0.5
55	Medio	Alta	Alta	Media	Alta	Baja	Muy Baja	Alta	0
56	Medio	Media	Alta	Media	Alta	Baja	Muy Baja	Alta	1
57	Medio	Baja	Alta	Media	Alta	Baja	Muy Baja	Alta	1
58	Pocas	Alta	Alta	Media	Muy Alta	Baja	Muy Baja	Media	0

59	Muy Pocas	Media	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Media	1
60	Medio	Media	Alta	Medio Baja	Alta	Baja	Baja	Alta	1
61	Pocas	Alta	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Media	1
62	Muy Pocas	Alta	Alta	Baja	Muy Alta	Baja	Muy Baja	Media	0
63	Pocas	Alta	Medio Alta	Baja	Muy Alta	Baja	Muy Baja	Media	1
64	Muy Pocas	Media	Alta	Media	Alta	Baja	Muy Baja	Alta	1
65	Muy Pocas	Alta	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Baja	0.5
66	Medio	Alta	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Alta	1
67	Muchas	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Muy Alta	0
68	Pocas	Alta	Alta	Media	Alta	Baja	Muy Baja	Alta	1
69	Demasiadas	Alta	Muy Alta	Media	Media	Media	Muy Baja	Media	1
70	Muy Pocas	Alta	Alta	Medio Baja	Muy Alta	Baja	Muy Baja	Media	1
71	Muy Pocas	Alta	Medio Alta	Medio Baja	Muy Alta	Media	Muy Baja	Media	0.5
72	Muchas	Media	Muy Alta	Medio Baja	Alta	Baja	Muy Baja	Muy Alta	0.5
73	Pocas	Alta	Alta	Medio Baja	Muy Alta	Media	Muy Baja	Alta	1
74	Medio	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Alta	1
75	Muchas	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Alta	1
76	Medio	Media	Alta	Medio Baja	Alta	Baja	Muy Baja	Media	1
77	Demasiadas	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Muy Alta	0.5
78	Muchas	Alta	Muy Alta	Media	Alta	Baja	Muy Baja	Baja	1
79	Muchas	Alta	Alta	Media	Alta	Baja	Muy Baja	Muy Alta	1
80	Muchas	Alta	Alta	Media	Media	Media	Muy Baja	Muy Alta	1

81	Medio	Alta	Alta	Baja	Alta	Baja	Muy Baja	Alta	1
82	Medio	Alta	Alta	Medio Baja	Media	Baja	Muy Baja	Alta	1
83	Pocas	Alta	Alta	Media	Alta	Media	Muy Baja	Alta	0.5
84	Muchas	Alta	Alta	Medio Baja	Alta	Baja	Muy Baja	Media	0.5
85	Demasiadas	Media	Alta	Medio Baja	Alta	Media	Muy Baja	Muy Alta	0.5
86	Medio	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Alta	1
87	Muchas	Media	Muy Alta	Media	Media	Baja	Muy Baja	Media	0.5
88	Muchas	Media	Muy Alta	Media	Media	Baja	Muy Baja	Alta	1
89	Medio	Alta	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Alta	1
90	Muchas	Alta	Muy Alta	Media	Media	Baja	Muy Baja	Alta	1
91	Muchas	Baja	Muy Alta	Media	Media	Baja	Muy Baja	Alta	1
92	Muchas	Baja	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Media	0.5
93	Muchas	Baja	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Alta	1
94	Muy Pocas	Alta	Alta	Media	Media	Baja	Muy Baja	Baja	1
95	Muchas	Alta	Alta	Medio Baja	Alta	Media	Muy Baja	Alta	1
96	Medio	Alta	Alta	Media	Alta	Baja	Muy Baja	Media	1
97	Medio	Alta	Alta	Media	Alta	Media	Muy Baja	Alta	1
98	Muchas	Alta	Alta	Media	Media	Media	Muy Baja	Media	1
99	Medio	Alta	Muy Alta	Baja	Media	Baja	Muy Baja	Alta	1
100	Muy Pocas	Alta	Alta	Media	Media	Media	Muy Baja	Media	1
101	Pocas	Alta	Alta	Medio Baja	Media	Media	Muy Baja	Alta	0.5
102	Medio	Alta	Alta	Media	Media	Media	Muy Baja	Alta	0.5

103	Muchas	Alta	Muy Alta	Media	Media	Media	Muy Baja	Media	1
104	Muchas	Alta	Alta	Baja	Alta	Alta	Muy Baja	Media	1
105	Demasiadas	Media	Muy Alta	Medio Baja	Media	Baja	Muy Baja	Media	0.5
106	Muchas	Alta	Muy Alta	Medio Baja	Alta	Baja	Muy Baja	Media	1

Anexo D. Tabla de reglas y convenciones del modelo difuso.

Convenciones: horas de brillos solar (HBS), nubosidad (N), temperatura máxima (TMax), temperatura mínima (TMin), humedad relativa (HR), velocidad del viento (VV), precipitación (P) y radiación solar (RS).

#	HBS	N	TMax	TMin	HR	VV	P	RS	Peso
1	Muchas	-	-	-	-	-	-	Alta	1
2	Medio	-	-	-	-	-	-	Media	0.5
3	Muy Pocas	Alta	Media	Media	Media	Media	Muy Baja	Muy Baja	0.5
4	Muchas	Baja	Alta	Muy Alta	Baja	Media	Muy Baja	Baja	1
5	Muchas	Alta	Alta	Alta	Baja	Baja	Muy Baja	Media	1
6	Medio	Medio Baja	Alta	Baja	Baja	Muy Baja	Muy Baja	Alta	1
7	Muchas	Baja	Alta	Media	Alta	Muy Baja	Baja	Muy Alta	1
8	Muchas	Muy Baja	Muy Alta	Muy Alta	Baja	Muy Baja	Muy Baja	Muy Alta	1
9	Medio	Media	Media	Baja	Alta	Muy Baja	Media	Muy Alta	1
10	Muchas	Alta	Alta	Media	Alta	Baja	Media	Muy Alta	1
11	Medio	Medio Baja	Media	Muy Baja	Baja	Baja	Muy Baja	Muy Alta	1
12	Muchas	Muy Alta	Media	Media	Alta	Alta	Muy Baja	Muy Alta	1
13	Muchas	Muy Baja	Muy Alta	Media	Baja	Muy Baja	Muy Baja	Baja	1
14	Pocas	Alta	Media	Alta	Muy Alta	Muy Baja	Muy Baja	Baja	0.5
15	Muchas	Baja	Alta	Media	Alta	Alta	Baja	Muy Alta	1
16	Muchas	Muy Alta	Media	Alta	Baja	Muy Alta	Muy Baja	Muy Baja	1
17	Demasiadas	Baja	Alta	Alta	Baja	Baja	Muy Baja	Muy Alta	1
18	Muy Pocas	Alta	Media	Alta	Muy Alta	Muy Baja	Baja	Baja	1
19	Muchas	Media	Alta	Muy Alta	Baja	Media	Muy Baja	Muy Alta	1

20	Pocas	Muy Alta	Media	Baja	Baja	Muy Baja	Muy Baja	Muy Baja	1
21	Medio	Alta	Alta	Baja	Baja	Muy Baja	Muy Baja	Muy Alta	1
22	Muchas	-	-	-	-	-	-	Media	0.5
23	Muchas	Baja	Alta	Baja	Baja	Baja	Muy Baja	Baja	1
24	Pocas	Baja	Alta	Media	Alta	Muy Baja	Muy Baja	Alta	0.5
25	Muchas	Media	-	-	-	-	-	Muy Alta	1
26	Demasiadas	Muy Alta	-	-	-	-	-	Muy Baja	1
27	Muchas	-	-	-	-	Muy Alta	-	Baja	0.5
28	Demasiadas	Baja	-	-	-	-	-	Muy Alta	0.5
29	Muchas	-	Media	-	-	-	-	Media	1
30	Medio	-	-	Alta	-	-	-	Media	1
31	Demasiadas	-	-	-	Alta	-	-	Media	1
32	Muchas	-	-	-	-	-	Media	Baja	1
33	-	-	-	-	-	Muy Alta	-	Media	0.5
34	Demasiadas	-	-	-	-	Muy Alta	-	Muy Baja	1
35	Pocas	-	Alta	-	-	Muy Alta	-	Muy Baja	1
36	Demasiadas	Muy Baja	-	Baja	-	-	-	Muy Alta	1
37	Muy Pocas	Media	-	Media	-	-	-	Muy Baja	0.5
38	Medio	-	-	Media	-	Muy Alta	-	Muy Baja	0.5
39	Muchas	Medio Baja	-	-	-	Muy Baja	-	Muy Alta	1
40	Demasiadas	Baja	-	Muy Alta	-	-	-	Muy Baja	1
41	Medio	Baja	-	Muy Baja	-	-	-	Muy Alta	0.5
42	Muchas	Baja	-	-	-	-	Muy Baja	Muy Alta	1
43	Demasiadas	-	Muy Alta	-	-	Muy Baja	-	Muy Baja	1

44	Muy Pocas	Medio Baja	Baja	-	-	-	-	Baja	1
45	Muy Pocas	-	-	Alta	-	-	Muy Alta	Baja	0.5
46	Medio	Muy Baja	Muy Alta	-	-	-	-	Muy Alta	1
47	Demasiadas	-	-	Muy Baja	Alta	-	-	Baja	1
48	Demasiadas	Alta	-	Media	-	-	-	Muy Baja	1
49	Demasiadas	Baja	Muy Alta	-	-	-	-	Muy Alta	1
50	Demasiadas	Muy Baja	Muy Alta	-	-	-	-	Baja	0.5
51	Medio	Muy Alta	Media	Media	Baja	Media	Muy Baja	Alta	1
52	Medio	Alta	Media	Baja	Media	Baja	Muy Baja	Alta	1
53	Pocas	Medio Baja	Media	Alta	Alta	Media	Muy Baja	Baja	1
54	Medio	Baja	Media	Alta	Alta	Muy Baja	Muy Baja	Alta	1
55	Medio	Alta	Media	Alta	Alta	Media	Muy Baja	Baja	1
56	Medio	Alta	Media	Alta	Baja	Muy Alta	Baja	Muy Baja	1
57	Muy Pocas	Alta	Media	Media	Alta	Media	Muy Baja	Muy Baja	1
58	Pocas	Media	Media	Alta	Baja	Muy Baja	Muy Baja	Muy Baja	0.5
59	Medio	Alta	Media	Media	Media	Muy Baja	Baja	Alta	0.5
60	Medio	Baja	Media	Media	Alta	Muy Baja	Muy Baja	Alta	1
61	Pocas	Baja	Media	Media	Alta	Muy Baja	Alta	Alta	1
62	Pocas	Alta	Media	Alta	Baja	Muy Alta	Muy Baja	Alta	0.5
63	Muchas	Alta	Alta	Alta	Media	Alta	Muy Baja	Muy Alta	1
64	Medio	Baja	Media	Baja	Alta	Baja	Baja	Muy Alta	1
65	Medio	Media	Media	Media	Muy Alta	Muy Baja	Media	Muy Alta	1

66	Pocas	Alta	Media	Alta	Baja	Baja	Muy Baja	Baja	1
67	Muy Pocas	Media	Media	Muy Alta	Media	Media	Baja	Media	1
68	Medio	Alta	Alta	Media	Media	Baja	Muy Baja	Alta	0.5

Anexo E. Tabla de reglas y convenciones del modelo difuso.

Convenciones: horas de brillos solar (HBS), nubosidad (N), temperatura máxima (TMax), temperatura mínima (TMin), humedad relativa (HR), velocidad del viento (VV), precipitación (P) y radiación solar (RS).

#	HBS	N	TMax	TMin	HR	VV	P	RS	Peso
1	Muchas	-	-	-	-	-	-	Alta	1
2	Medio	-	-	-	-	-	-	Media	0.5
3	Demasiadas	-	-	-	-	-	-	Alta	1
4	Muchas	-	-	-	-	-	-	Media	0.5
5	Demasiadas	-	-	-	-	-	-	Muy Alta	0.5

Modelo de Predicción de Radiación Solar usando Técnicas Inteligentes

Solar Radiation Prediction Model using Intelligent Techniques

Juan Sebastián Mejía Rincón^{1*} y Vladimir Mosquera Cerquera²

Fecha de recibo: Junio 2019

Fecha de revisión:

Fecha de aprobación:

Resumen

Muchas de las actividades desarrolladas por el ser humano dependen de los cambios de las variables meteorológicas y sus efectos. La radiación solar es la mayor fuente de energía para los seres vivos e influye en el correcto funcionamiento de los procesos atmosféricos y climáticos. La necesidad de conocer el comportamiento de la radiación solar para el desarrollo de diversas actividades da como resultado la elaboración de técnicas y procesos que permitan medirlas y estimarlas correctamente. El estudio de la radiación solar es muy pertinente debido al gran campo aplicaciones que posee; entre ellos el diseño de estaciones fotovoltaicas, en el área agrícola, estudios meteorológicos y para el desarrollo de modelos físicos. La medición de la radiación solar es compleja, esto se debe a los altos costos de los instrumentos de medición y su poca disponibilidad comercial. La estimación de la radiación solar es una alternativa a este problema. Entre los métodos de estimación mayormente usados se destacan los estadísticos, matemáticos, físicos y computacionales. Este proyecto se enfoca en los modelos computacionales basados en Inteligencia Artificial, que mediante técnicas como las Redes Neuronales Artificiales (RNA) y Lógica Difusa prometen predicciones precisas.

Palabras clave: radiación solar, variables meteorológicas, predicción, energía, Redes Neuronales Artificiales, Lógica Difusa, Inteligencia Artificial.

Abstract

Many human activities depend on changes in weather variables and their effects. Solar radiation is the major source of energy for living beings and influences the proper functioning of atmospheric and climatic processes. The need to know the behaviour of solar radiation for the development of various activities results in the development of techniques and processes to measure and estimate them correctly. The study of solar radiation is very relevant due to the large field of applications it possesses; among them the design of photovoltaic stations, in the agricultural area, meteorological studies and for the development of physical models. The measurement of solar radiation is complex, this is due to the high costs of measuring instruments and their limited commercial availability. The estimation of solar radiation is an alternative to this problem. The most commonly used estimation methods include statistics, mathematics, physics and computational methods. This project focuses on computational models based on Artificial Intelligence, which through techniques such as Artificial Neural Networks (ANN) and Fuzzy Logic promise accurate predictions.

Keywords: solar radiation, meteorological variables, prediction, energy, Artificial Neural Networks, Fuzzy Logic, Artificial Intelligence.

¹ Estudiante de Ingeniería Electrónica, Universidad Surcolombiana, Neiva, Colombia. u20131117492@usco.edu.co. *(Autor para correspondencia)

² Magister en Ingeniería Electrónica, Universidad del Valle. Docente Universidad Surcolombiana, Neiva, Colombia. vmosquera@usco.edu.co

1. Introducción

El afán de conocer con exactitud el comportamiento de variables climatológicas para el desarrollo de diversas actividades humanas da como resultado la elaboración de técnicas que permitan estimarlas de manera correcta. Entre estos métodos destacan los estadísticos, matemáticos, físicos y computacionales. Este proyecto se enfoca en los modelos computacionales basados en Inteligencia Artificial, que mediante técnicas de aprendizaje e inferencia prometen resultados interesantes.

La radiación solar es la energía emitida por el sol que viaja a través del espacio en forma de ondas electromagnéticas y, como se ha mencionado anteriormente, es la mayor fuente de energía para todas las formas de vida terrestres, además de que es un factor fundamental en el análisis del clima y su unidad de medida es W/m^2 , es decir, Vatio por unidad de superficie.

El pronóstico preciso de la radiación solar es bastante pertinente ya que tiene un gran campo de aplicaciones; por ejemplo, la radiación solar es importante en el diseño de estaciones fotovoltaicas para garantizar la estabilidad de la energía eléctrica generada. En el área agrícola es relevante ya que permite el monitoreo y control del crecimiento de algún cultivo. Sin embargo, como se mencionó anteriormente, la medición de la radiación solar es complicada ya que los equipos con los cuales se pueden adquirir los datos son bastante costosos (pirheliómetros y piranómetros) y no se consiguen en todas partes, así que dificulta la posibilidad de tener una base de datos confiable en países poco desarrollados (Sayago, *et al.*, 2011). Por todo lo mencionado anteriormente nace el interés por encontrar la forma más adecuada de estimación de radiación solar.

El proyecto está orientado al desarrollo de un modelo de predicción de radiación solar por medio de inteligencia computacional en el área urbana de la ciudad de Neiva. El municipio de Neiva es muy importante para la región surcolombiana del país debido a una economía dinámica basada en el ecoturismo, gastronomía, industria y comercio. “Debido a su ubicación cerca de la línea del ecuador y su baja altitud, la ciudad tiene un clima cálido con temperaturas anuales promedio durante el día que van desde 21 hasta 35 grados centígrados. La temperatura de esta zona conserva cierta relación con las lluvias, la época más caliente se sitúa en los meses de agosto y septiembre que son los de menor precipitación atmosférica, cuando la máxima temperatura sobrepasa los 37 °C” (Wikipedia, 2016). Los meses más frescos son los que presentan alternancia de lluvias con calor, como abril, noviembre y diciembre. En este tiempo la temperatura varía entre 28 °C y 30 °C. La temperatura promedio es de 27 °C (IDEAM, 2015). Las condiciones climáticas del municipio son adecuadas para obtener datos históricos completos de las variables meteorológicas ya que Neiva es un municipio que está expuesto a microclimas, como todas las zonas del país, pero son menos pronunciados si se comparan con otros municipios, lo cual implica una mejor conservación de los instrumentos de medición y esto lleva a obtener datos completos y precisos, evitando hacer procedimientos y preprocesamientos que puedan aumentar la incertidumbre de dichos datos.

Los modelos computacionales desarrollados en este proyecto son las RNA y Lógica Difusa. Las RNA permiten solucionar problemas complejos y no lineales, porque mediante el entrenamiento de la red neuronal, esta aprende el comportamiento de los datos de entrada con respecto a los datos de salida y puede replicarlo con precisión sin importar si se cambian los datos de entrada para conseguir datos de salida deseados. El modelo difuso utiliza reglas de inferencia para relacionar los datos de entrada con los de salida mediante reglas, las cuales son establecidas por un experto, quien debe conocer muy bien el comportamiento de los datos. Ambos modelos están basados en Inteligencia Artificial y permiten cumplir con las metas propuestas al desarrollar este proyecto: estimar la radiación solar a partir de datos históricos de variables meteorológicas de fácil adquisición usando algoritmos que puedan remplazar los métodos convencionales.

A nivel nacional ya se cuenta con investigaciones hechas en este campo, como en la Escuela de Ingeniería de Antioquia, en la que se desarrolla un modelo de predicción de la radiación solar que incide sobre los vehículos solares que compiten en el World Solar Challenge 2013 en cinco localidades cercanas a la carretera donde se lleva a cabo la competencia mediante modelos basados en Redes Neuronales (González, 2013).

En América Latina también se han realizado investigaciones con respecto a la estimación de radiación solar a partir de técnicas inteligentes, por ejemplo, en la Universidad de Córdoba desarrollaron seis modelos de redes de tipo perceptrón multicapa con propagación de la información hacia adelante los cuales incluyen una capa de entrada, una capa oculta y una salida que mostraba la radiación solar promedio estimada cada treinta minutos (Sayago, *et al.*, 2011).

En India formularon modelos de predicción de radiación solar basados en redes neuronales artificiales para identificar en que zonas de la India se obtiene una mejor producción de energía solar (Yadav, *et al.*, 2014). Los modelos neuronales utilizados son perceptrón multicapa. Usan una herramienta llamada WEKA para identificar las variables más relevantes, concluyendo que la longitud y la latitud son las variables menos influyentes en la predicción.

En España no solo proponen una predicción temporal de la radiación solar, en la Universidad Politécnica de Madrid desarrollan un modelo de predicción espacial y temporal de la irradiancia global, mediante RNA para la predicción temporal y geoestadística para la predicción espacial, con el propósito de generar mejores modelos predictivos que ayuden en la estimación de la producción de energía renovable procedente del sol (Gutiérrez, 2014). Esta investigación se profundiza cuando proponen un método de pronóstico de irradiación solar intra-día que utiliza RNA a partir de sensores, donde se confirma la influencia de sensores vecinos en la predicción a corto plazo validando los modelos para ventanas de tiempo de 1 a 6 h con sensores dentro de un radio de 55 km (Gutiérrez, *et al.*, 2016).

De acuerdo con todo lo mencionado, la importancia de este trabajo investigativo radica en el uso de técnicas de inteligencia computacional como lo son las Redes Neuronales Artificiales y Lógica Difusa ya que pueden manejar grandes cantidades de datos y suministrar predicciones rápidas y apropiadas, con el fin de pronosticar datos de radiación solar que puedan llegar a ser usados en procesos biológicos, meteorológicos, sistemas de producción de energía, uso más eficiente del agua para el riego y mejoramiento de la gestión de los sistemas públicos de iluminación. Para implementar los modelos propuestos se hace uso del software Matlab.

2. Materiales y métodos

En primer lugar, se va a plasmar el modelo implementado con Lógica Difusa y en segundo lugar se va a explicar el desarrollo del modelo basado en RNA. Los datos de las variables meteorológicas fueron facilitados por IDEAM. Los datos de entrada de los modelos se toman de la base de datos ofrecida por el Aeropuerto Benito Salas y los datos de radiación solar se toman de la estación La Plata. La serie temporal de datos se toma desde el 1 de febrero de 2013 hasta el 30 de septiembre de 2016.

2.1. Modelo Difuso

Se usó la lógica difusa para el desarrollo de este modelo debido a las ventajas que ofrece, como su facilidad de implementación y un gran desempeño frente a sistemas no lineales ya que no depende de ecuaciones ni modelos matemáticos complejos (Campos, *et al.*, 2018), solo se necesita conocer el comportamiento del sistema para poder definir con claridad las reglas de inferencia que reflejan las condiciones del sistema difuso. Para la implementación de este modelo se usó la herramienta Fuzzy Logic Designer del tool Fuzzy Logic de Matlab, la cual permite definir el tipo de sistema difuso, el número de variables de entrada y salida, el número y el tipo de funciones de membresía y el universo de discurso. En la Figura 1 se muestra la representación genérica del modelo difuso.

Se define un sistema difuso Mamdani porque es fácil de aplicar y cuenta con defuzzificador que permite tomar la salida difusa y convertirla en salida numérica para que pueda ser interpretada por elementos externos como controladores. También se definen siete variables de entrada y una variable de salida y la serie temporal de los

datos se especifica desde el 1 de enero hasta el 30 de septiembre del 2016. Las variables de entrada del modelo son horas de brillo solar, nubosidad, temperatura máxima, temperatura mínima, humedad relativa, velocidad del viento, precipitaciones y la variable de salida es radiación solar. Se eliminan los datos incompletos de radiación solar, después se buscan en las variables de entrada los días en los cuales los datos de radiación fueron eliminados y también se descartan. Se establecen cinco funciones de membresía para cada variable meteorológica, excepto nubosidad la cual cuenta con seis. Para las variables de entrada las funciones de membresía fueron gaussianas tipo 1 y para la variable de salida fueron gaussianas tipo 2. La distribución de las funciones de membresía se hizo con a un análisis de frecuencia de cada variable. Las funciones de membresía deben estar superpuestas ya que según expertos y la literatura los niveles lingüísticos tienen límites grises los cuales pueden estar definidos en las intersecciones de las funciones (McCauleyBell P & Crumpton, 2000). En este modelo se utilizaron 68 reglas de inferencia, las cuales se definieron según la correlación entre variables y de manera heurística.

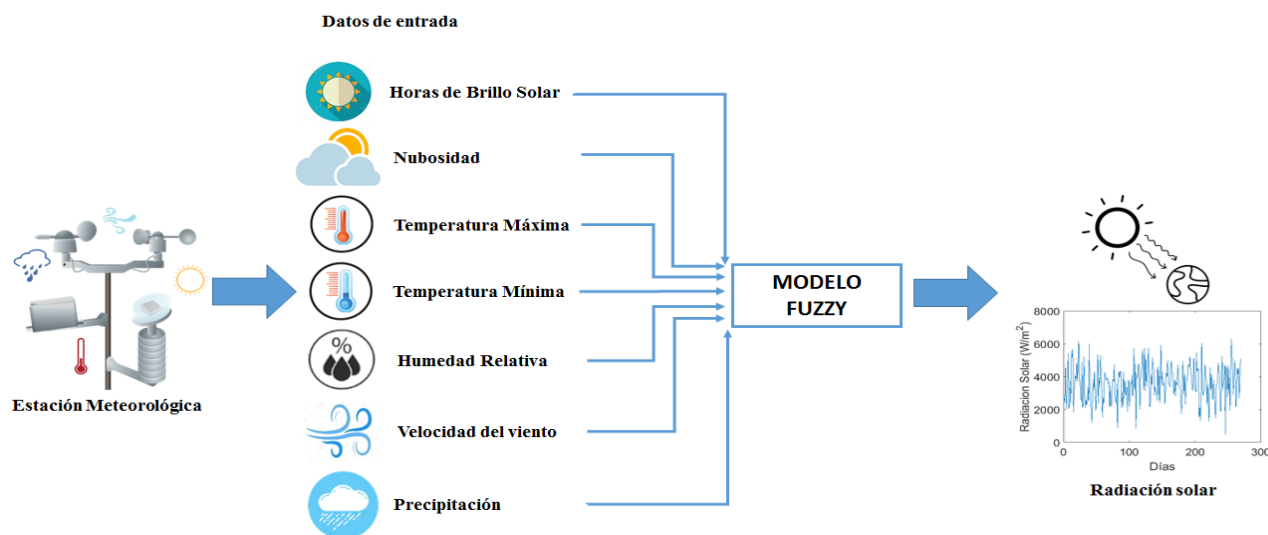


Figura 1. Representación genérica del modelo de predicción fuzzy.

De la Figura 2 hasta la Figura 9 se presentan las funciones de membresía de cada variable. En cada figura se observa el rango definido para cada variable y el universo de discurso con el cual se etiqueta cada función de membresía.



Figura 2. Funciones de membresía de horas de brillo solar.




Figura 3. Funciones de membresía de nubosidad.




Figura 4. Funciones de membresía de temperatura máxima.




Figura 5. Funciones de membresía de temperatura mínima.




Figura 6. Funciones de membresía de humedad relativa.




Figura 7. Funciones de membresía de velocidad del viento.




Figura 8. Funciones de membresía de precipitación.




Figura 9. Funciones de membresía de radiación solar.

2.2. Modelo neuronal

Se utilizaron las RNA para desarrollar este modelo, que permiten resolver problemas complejos, como sistemas no lineales. Tomando datos históricos de las variables de interés son capaces de aprender el comportamiento de esos datos y replicarlo incluso si se cambia el conjunto de datos dado inicialmente. Pueden responder a situaciones a las cuales no han sido expuestas o que tengan información distorsionada, generalizan a partir de casos anteriores. Las RNA son modelos matemáticos inspirados en el funcionamiento del cerebro, son aproximadores no lineales que “imitan” el comportamiento de las redes neuronales biológicas. Para este modelo neuronal se utiliza una base de datos que va desde el 1 de febrero del 2013 hasta el 30 de septiembre del 2016, donde los datos utilizados para el entrenamiento del modelo son los que pertenecen al periodo desde el 1 de febrero del 2013 hasta el 31 de diciembre del 2015 y para la predicción se usan los datos desde 1 de enero hasta el 30 de septiembre del 2016. En la Figura 10 se muestra la representación genérica del modelo neuronal.

Para el modelo neuronal desarrollado en el proyecto “Modelo de Predicción de Radiación Solar usando Técnicas Inteligentes” se propone un modelo compuesto por RNA feed-forward y SOM (Mejía, 2019). Las redes SOM o mapas auto-organizados poseen un aprendizaje no supervisado competitivo, donde no se conoce la salida del sistema por lo que debe basarse en los datos de entradas para cumplir con el objetivo. Las redes SOM deben identificar rasgos similares y correlaciones en los datos de entrada y agruparlos. Las redes feed-forward son un conjunto de neuronas que reciben información de muchas variables, la procesan y luego dan una respuesta que puede ser multivariable también. Ingresan los datos a través de las neuronas de la capa de entrada, y al pasar la información a la capa oculta, las neuronas reciben la suma ponderada de las entradas que están conectadas a ella; las conexiones entre neuronas representan un peso de conexión. Las redes feed-forward tiene un aprendizaje supervisado, el cual involucra un ajuste de los pesos comparando la salida deseada con la respuesta de la red de manera que el error sea mínimo.

En este artículo se pretende plasmar otro modelo neuronal desarrollado con redes feed-forward que presenta un mejor rendimiento comparado con el modelo neuronal de redes SOM y feed-forward (Mejía, 2019). El modelo neuronal tiene dos capas ocultas, se hace un barrido de neuronas modificando el número de neuronas por capa, se aumenta el número de neuronas de diez en diez y el máximo de neuronas por capa es de cien. Se prueba el modelo cinco veces para cada combinación, de esta forma se prueba la precisión y exactitud del modelo, es decir la repetibilidad y fidelidad de los resultados. El algoritmo de entrenamiento utilizado es el Levenberg–Marquardt. Lo que diferencia este modelo neuronal es que solo se trabaja con una variable de entrada, la cual es horas de brillo solar; esto se debe a que es la variable más relevante teniendo en cuenta los cálculos del coeficiente de

correlación de Pearson de cada variable y los resultados obtenidos por el modelo difuso. La variable de salida es radiación solar.



Figura 10. Representación genérica del modelo de predicción neuronal.

3. Resultados y discusión

En esta sección se muestran los resultados obtenidos por los dos modelos propuestos que permiten predecir la radiación solar, basados en técnicas de inteligencia computacional, los cuales generan resultados de predicción que conllevan a conclusiones relevantes para el estado del arte.

Los dos modelos propuestos para predecir la radiación solar nacen como alternativas a las estimaciones presentadas por los sistemas estadísticos y matemáticos generalmente usados. A continuación, se relacionan los cálculos correspondientes para medición de rendimiento y eficiencia de los modelos. El rendimiento de estos modelos se evalúa estadísticamente utilizando el coeficiente de determinación expresado como R^2 . Se hace uso de la siguiente expresión para el cálculo de este coeficiente:

(1)

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2}$$

3.1. Modelo difuso

El rendimiento obtenido por el modelo difuso es el esperado con pequeños desaciertos, debido a las diversas perturbaciones existentes en los datos que se explican a continuación. En la Figura 11, se muestra el resultado del modelo, la predicción de datos de radiación solar. En la gráfica correspondiente a esta figura, se plasma una comparación entre los datos predichos o estimados de radiación y los datos reales.

No se planteó un suavizado de datos de entrada ni un proceso de normalización porque se determinó que la predicción fuera con los datos obtenidos directamente por medición. Los rangos de las funciones de membresía se ajustaban de acuerdo a las escalas de datos de cada variable.

El comportamiento de los datos estimados es similar al de los datos reales, pero no son los mismos, porque el modelo de predicción se queda algo corto cuando hay cambios bruscos en las mediciones de radiación solar. Se nota que cuando se presentan picos de radiación solar medida el modelo no los puede predecir porque las reglas entran en conflicto entre sí; se realizaron pruebas donde se definieron reglas para ciertos picos de radiación solar basándose en los datos de las variables de entrada para esos días específicos con la intención de estimar la radiación solar en los días definidos, pero no fue posible, porque las reglas expuestas eran redundantes o no cumplían con su objetivo ni mejoraban el rendimiento del modelo, es por esto que las reglas de inferencia que se probaron fueron eliminadas del modelo.




Figura 11. Predicción de radiación solar obtenida por el modelo difuso.

Se calculó el coeficiente de determinación utilizando la expresión (1). El valor obtenido fue de 0.5830. Analizando este resultado se puede decir que el modelo es capaz de predecir más de la mitad de los datos de radiación solar, que equivalen aproximadamente a una predicción de radiación solar de 157 días, teniendo en cuenta que el conjunto de datos de validación corresponde a 269 días. El modelo de predicción desarrollado en este trabajo es de predicción a largo plazo, lo cual hace que sea menos causal que los modelos a corto plazo comúnmente presentados en el estado del arte.

3.2. Modelo neuronal

El rendimiento obtenido por el modelo neuronal es bueno, pero cuenta con pequeños desaciertos, esto se debe a las diversas perturbaciones existentes en los datos que se explican a continuación. En la Figura 12, se muestra el resultado del submodelo que presentó un mejor rendimiento, el modelo que cuenta con 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa. En la gráfica correspondiente a esta figura, se plasma una comparación entre los datos predichos o estimados de radiación y los datos reales.

No se planteó un suavizado de datos de entrada ni un proceso de normalización porque los resultados que proporcionaban eran ligeramente mejores o iguales a los datos reales sin procesar así que se consideró que no valían la pena. En la Tabla 1 se relacionan los resultados más relevantes obtenidos por el modelo neuronal calculando el coeficiente de determinación utilizando la Ecuación 1; en dicha tabla se resalta el mejor resultado, el cuál es el submodelo que cuenta con 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa porque obtiene un buen resultado y el submodelo es preciso, hay repetibilidad en los resultados.

Los datos de radiación solar estimados por el modelo neuronal presentan un comportamiento análogo al de los datos reales de radiación solar, pero no es igual debido a que el modelo de predicción neuronal no alcanza los valores de radiación solar cuando hay cambios bruscos en las mediciones de radiación solar de un día a otro.




Figura 12. Predicción de radiación solar obtenida por el modelo neuronal con 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa oculta.

Como se expresó con anterioridad el modelo neuronal con mejor rendimiento es el que posee 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa oculta. El resultado obtenido fue de 0,2158. Analizando este resultado se puede decir que el modelo neuronal es capaz de predecir más del 20% de los datos de radiación solar, que equivalen aproximadamente a una predicción de radiación solar de 58 días, teniendo en cuenta que el conjunto de datos de validación corresponde a 269 días. Se debe tener en cuenta que la predicción es a largo plazo y estos resultados son muy relevantes. Además, este modelo neuronal presenta un mejor resultado que el modelo neuronal con redes SOM y feed-forward planteado en el proyecto “Modelo de Predicción de Radiación Solar usando Técnicas Inteligentes”, pero se debe indicar que coinciden en la cantidad de neuronas en las capas ocultas que poseen los submodelos con mejor rendimiento.

Tabla 1. Resultados relevantes del modelo neuronal con una variable de entrada.

Capa Oculta		Capa de Entrada	Coeficiente de determinación (R^2)			
Número de neuronas		Número de entradas	Entrenamiento		Prueba	
Capa 1	Capa 2	#	Mínimo	Máximo	Mínimo	Máximo
20	0	1	0,2783	0,292	0,1931	0,2187
20	10	1	0,2929	0,3001	0,2132	0,2158
50	10	1	0,3076	0,3179	0,2031	0,2169
10	20	1	0,2897	0,2914	0,1211	0,2236
30	20	1	0,2946	0,325	-0,0508	-0,0166
60	20	1	0,3168	0,3294	0,0142	0,0567
40	50	1	0,3104	0,3235	-0,2235	-0,04
30	70	1	0,3121	0,3183	-0,1378	0,2434
20	80	1	0,295	0,315	0,0733	0,0988
40	90	1	0,3232	0,3355	-0,2555	0,1863
50	100	1	0,2814	0,339	-0,2717	0,1341

4. Conclusiones

Se implementaron los modelos propuestos de predicción de radiación solar, un modelo usando redes neuronales artificiales y el otro empleando lógica difusa. Con estos modelos se pretende aumentar el interés por la estimación de datos meteorológicos mediante técnicas basadas en principios de inteligencia artificial que permitan el pronóstico de datos cuya medición sea costosa y compleja; además de surgir como una alternativa a los modelos clásicos. Los datos fueron facilitados por IDEAM y provienen de estaciones meteorológicas reguladas y certificadas. Se tomó la decisión de utilizar los datos que provienen de la estación meteorológica del Aeropuerto Benito Salas, excepto los de radiación solar ya que esta estación no cuenta con datos actualizados. Para los datos de radiación solar se tomaron los medidos por la estación La Plata. Se aplica un preprocesamiento el cual elimina los datos incompletos; este método toma los días que presentan una radiación solar menor de 10, luego busca esos mismos días en las series temporales de todas las variables meteorológicas y los elimina.

El modelo neuronal se implementó usando redes feed-forward. El modelo cuenta con aprendizaje supervisado. La red feed-forward cuenta con 2 capas ocultas y algoritmo de entrenamiento Levenberg–Marquardt; se hace un barrido del número de neuronas de las capas ocultas, el cual se aumenta de diez en diez hasta llegar a cien en cada capa, este proceso permite identificar con que combinación se obtiene un mejor resultado. Se realizan pruebas del modelo neuronal cinco veces para cada combinación para identificar la precisión y exactitud del modelo. Para este modelo solo se utiliza la variable horas de brillo solar, se toma a partir del análisis de variables relevantes y los resultados obtenidos del modelo difuso. El modelo neuronal puede llegar a estimar valores cercanos de radiación solar en algunos días. El mejor rendimiento del modelo neuronal fue el que se obtuvo con 20 neuronas en la primera capa oculta y 10 neuronas en la segunda capa. La predicción fue del 21,58%, esto refleja un resultado bueno teniendo en cuenta que es predicción a largo plazo, además de que solamente se usó una variable de entrada. Esto difiere del resultado obtenido por el modelo propuesto en el artículo “Solar Radiation Prediction Using Radial Basis Function Models” donde afirman que los modelos con mayor número de variables de entrada, independientemente de del número de neuronas proporcionan una mejor predicción (Mutaz T & Ahmad, 2015). Aunque el resultado del modelo neuronal feed-forward con una variable de entrada es mejor al obtenido por el modelo neuronal desarrollado con redes SOM y feed-forward, se debe indicar que ambos modelos cuentan con el mismo número de neuronas en las dos capas ocultas, lo que permite concluir que la combinación de neuronas más eficiente es 20 neuronas para la primer capa y 10 neuronas para la segunda capa.

Para el modelo difuso se diseñó un sistema de tipo Mamdani, con siete variables de entrada y una de salida. Cada variable cuenta con cinco funciones de membresía, excepto nubosidad la cual tiene seis funciones. Se definieron claramente los rangos de cada variable para poder distribuir las funciones de membresía de tal forma que quedaran superpuestas y así evitar incertidumbres. Se optó por funciones gaussianas tipo 1 para las entradas y gaussianas tipo 2 para la salida ya que los datos están acotados, además de que la sección de mayor relevancia puede ser determinada por un conjunto de datos y no un dato específico. La cantidad de funciones y la distribución de estas se pudo definir graficando la frecuencia de los datos de cada variable. El modelo difuso obtuvo una predicción de radiación solar del 58.3%. Esto indica que el modelo es capaz de predecir la radiación solar de 157 días. Fue una decisión muy acertada implementar las funciones de membresía basándose en las gráficas de frecuencia de cada variable, ya que con esas gráficas se pudo definir la distribución de las funciones y el número de estas para cada variable.

Si se comparan directamente ambos modelos, neuronal y difuso, el modelo difuso es mejor. El modelo difuso permite estimar datos muy cercanos a los datos medidos. A pesar de que no puede estimar los valores críticos de radiación solar, se evidencia que para esos días estima datos medios; esto es una ventaja porque asegura valores de radiación solar para esos días que son por debajo a los reales, por lo que si se obtienen valores de radiación solar mayores a los pronosticados puede generar ganancias. El modelo neuronal también predice datos de radiación solar muy cercanos a los medidos, pero no en su totalidad, aunque los resultados fueron bastante relevantes teniendo en cuenta que solo se usó una variable de entrada y no se hizo preprocesamiento de datos. Como se ha venido mencionando, todos los resultados obtenidos son relevantes e importantes aportes al estado

del arte. El modelo neuronal es un modelo interesante que se puede seguir probando hasta conseguir los resultados esperados, la clave consiste en persistir. Lo mismo ocurre con el modelo difuso, el cual puede ser mucho más preciso. Como afirmaba Thomas Edison: “no son fracasos, son intentos”. Esta investigación debe continuar para obtener resultados mejores, además de seguir contribuyendo al desarrollo científico y promover el interés en la predicción de datos meteorológicos.

5. Referencias bibliográficas

Sayago S., Bocco M., Ovando G., Willington E., 2011. Radiación solar horaria: Modelos de estimación a partir de variables meteorológicas básicas. Universidad Córdoba. Avances en Energías Renovables y Medio Ambiente.

Wikipedia, 2016. Neiva: <https://es.wikipedia.org/wiki/Neiva>. Consultado 10 de septiembre de 2017.

IDEAM, 2015. Características climatológicas de ciudades principales y municipios turísticos: <http://www.ideam.gov.co/documents/21021/418894/Caracter%20C3%ADsticas+de+Ciudades+Principales+y+Municipios+Tur%20C3%ADsticos.pdf/c3ca90c8-1072-434a-a235-91baee8c73fc>. Consultado 08 de junio de 2019.

González A., 2013. Modelo para la predicción de la radiación solar a partir de redes neuronales artificiales. Escuela de Ingeniería de Antioquia.

Yadav A., Malik H., S.S.Chandel, 2014. Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. Renewable and Sustainable Energy Reviews, Volume 31, Pages 509-519. <http://dx.doi.org/10.1016/j.rser.2013.12.008>.

Gutiérrez V., 2014. Predicción espacio-temporal de la irradiancia solar global a corto plazo en España mediante geoestadística y redes neuronales artificiales. Universidad Politécnica de Madrid.

Gutiérrez V., Manso M., Moreno M., Manrique M., 2016. Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations. Solar Energy, Volume 134, Pages 119-131. <https://doi.org/10.1016/j.solener.2016.04.020>.

Campos F., Saavedra V., Robayo F., 2018. Sistema de control de altura del quadrotor AR. Drone 2.0 mediante lógica difusa en un ambiente controlado. Universidad Surcolombiana.

McCauleyBell P., Crumpton L., 2000. A fuzzy linguistic model for the prediction of carpal tunnel syndrome risks in an occupational environment. IBM Journal of Research and Development, Volume 44, Pages 759-769. <https://doi.org/10.1080/001401397187784>.

Mejía J., 2019. Modelo de Predicción de Radiación Solar usando Técnicas Inteligentes. Universidad Surcolombiana.

Mutaz T., Ahmad A., 2015. Solar Radiation Prediction Using Radial Basis Function Models. 2015 International Conference on Developments of E-Systems Engineering (DeSE), 2015 IEEE, Pages 77-82. <http://dx.doi.org/10.1109/DeSE.2015.55>.

Nomenclatura

y_i = Datos reales.

\hat{y}_i = Datos estimados.

\bar{y} = Media de datos.