



Pontificia Universidad
JAVERIANA
Colombia
Bogotá D.C

Las Redes Neuronales Artificiales como herramienta: Variables, Predicciones y Proyecciones para el Fenómeno Isla de Calor en Bogotá D.C

Valentina Zuluaga Patiño

Director de trabajo de grado:

Alex Mauricio González

Pontificia Universidad Javeriana

Facultad de Estudios Rurales y Ambientales

Carrera de Ecología

2018

Tabla de Contenido

1. Abstract	3
2. Introducción	3
2.1. Problemática.....	4
2.2. Justificación.....	4
2.3. Propósito.....	4
3. Objetivos.....	6
4. Marco Teórico	6
4.1. Ecología Urbana.....	6
4.2. Climatología	7
4.2.1. Fenómeno Isla de Calor.....	9
4.3. Propiedades de superficies.....	11
4.3.1. Superficies Urbanas: Edificios, cemento, asfalto.....	11
4.3.2. Albedo.....	12
4.3.3. Cobertura Vegetal y Evapotranspiración.....	12
4.4. Redes Neuronales.....	13
5. Antecedentes.....	15
6. Área de estudio	16
7. Materiales y métodos.....	18
7.1. Diseño de estudio.....	18
7.2. Métodos de recolección de datos.....	19
7.3. Métodos de análisis.....	20
8. Resultados.....	27
9. Discusión.....	34
9.1. Pesos sinápticos.....	35
9.2. Predicciones y proyecciones.....	39
9.3. Redes Neuronales.....	42
10. Conclusión.....	44
11. Referencias	46

1. Abstract

Urban Heat Island Effect (UHI) is a current and growing problem, present in many cities around the globe. It's defined as the increase in temperature from the rural to urban gradient. Caused mainly by changes in land cover, urban morphology, lack of vegetation and urban metabolism. UHI has been extensively explored through traditional statistical methods, due to the impacts it has on urban life and human health. Also, the threat it poses to the future of cities in climate change scenarios. This study proposes a different approach, via Artificial Neural Networks(ANNs) and Artificial Intelligence. ANNs are widely recognized in other fields for their ability to predict, recognize patterns and depict non-linear relationships. In ecology, ANNs are extensively recommended because of their ability to work with outliers, uncertainty and open systems; yet are seldomly used, due their notorious 'black box' reputation. ANNs main advantage is the ability to change their behaviour based on external information, that flows through the ANNs during the training phase. This study considers different variables constantly related to UHI, and evaluates the relative importance and the synaptic weights given to them by the ANN. It also evaluates the ability of the ANN to predict climate and its ability to project climate for future scenarios. Finally, it poses a question to whether they should be used as a tool in ecological studies. Aside from variables highly related to UHI like: precipitation, building height, vegetation areas; CO2 emissions was one of the variables with the highest relative importance. Prediction results, despite representing increasing amounts of variables and variation, were adjusted to the mean of the maximum temperature; and projections had a higher determination coefficient despite having less data as input. ANNs results need to be further transformed to be interpreted, they don't explicitly state relationships between variables and have too many options to represent the system being considered. In spite and in favour, ANNs are an excellent tool to explore ecological phenomena, that should be very thoroughly explored.

2. Introducción

2.1 Problemática

La urbanización es una de las actividades humanas más invasivas e irreversibles que hay (Seto et al. 2011). Esta cambia y altera la cobertura, los sistemas hidrológicos, la biogeoquímica, el clima y la biodiversidad (Grimm et al. 2015). Las áreas urbanas afectan los climas locales, ya que se alteran muchas de las propiedades originales del lugar. Dentro de sus propiedades se encuentra el albedo de la superficie, el cual disminuye, la evapotranspiración que también disminuye, y el aumento de aerosoles y las fuentes de calor, así aumentando la temperatura y alterando los patrones de precipitación (Rosenfeld 2000, Shepherd 2001). Uno de los principales fenómenos climáticos presentes en los ecosistemas urbanos es el fenómeno Isla de Calor. Este, que ocurre en lugares urbanizados, se define como el aumento en la temperatura en comparación con los lugares rurales aledaños (Oke 1987). La Isla de calor, es uno de los fenómenos climáticos más estudiados ya que ha sido reconocido desde 1820 por Luke Howard (Blake et al. 2011). Los estudios en relación con este fenómeno abundan y varían en metodología. La mayoría de las investigaciones estudian la Isla de Calor a través de análisis multi-temporales con imágenes satelitales o a través de los métodos estadísticos tradicionales (Blake et al. 2011). Si bien, ha sido extensamente evaluado, el fenómeno

Isla de calor varía en tamaño, duración y espacio dependiendo de diferentes características urbanas, factores meteorológicos y ubicación geográfica (Oke 1987). Cada ciudad presenta un caso diferente. A partir del 2010, se conoce que Bogotá presenta el fenómeno Isla de Calor, ya que existe una diferencia de temperatura de 3°C entre lo rural y el casco urbano (Angel et al. 2010).

Las ciudades son epicentro de rápida urbanización y crecimiento. En promedio, el crecimiento de las áreas urbanas duplica el crecimiento poblacional en las áreas rurales (Seto et al. 2012). En el 2011, la Organización para el Desarrollo y Cooperación Económica (OECD), estimó que para el 2030 más del 60% de la población mundial estaría viviendo en ciudades. Por otra parte, el Fondo Poblacional de las Naciones Unidas estimó en el 2017, que para el 2030, 5 billones de los 7.6 billones de habitantes estarían ubicados en ciudades. Es decir, las ciudades grandes seguirán creciendo y el fenómeno Isla de Calor empeorando. El fenómeno isla de calor es un riesgo y amenaza para la salud y bienestar humano, ya que empeora la calidad del aire (IPCC 2007) e impide que los contaminantes del aire fluyan a otros lugares (Touchaei et al. 2016). Las altas temperaturas también activan reacciones químicas que producen smog fotoquímico siendo este perjudicial para la salud (Mohajerani et al. 2017). Por último, el calor extremo puede causar golpe de calor, agotamiento por calor y muerte. En el 2018 alrededor de 100 personas murieron entre Japón y Canadá por las olas de calor en las ciudades (Hopps 2018, Kassam 2018). Así mismo, con el cambio climático el confort urbano se verá afectado, los humanos y la fauna tendrán un estrés de calor más alto, aumentará la demanda de aire acondicionado y se alterarán patrones de vegetación (Blake et al. 2011). La variabilidad climática y el cambio en la temperatura, nivel del mar, precipitación y eventos extremos tendrán un alto impacto sobre las funciones humanas y ecológicas en las áreas urbanas (Alberti 2008). Por lo tanto, es vital prevenir y mitigar el fenómeno Isla de Calor, ya este sigue aumentando en muchas ciudades, y con este, la demanda de energía para aire acondicionado (Alberti 2008). Para lograrlo se debe comprender el fenómeno en función de la ciudad en la que se ubica.

Según Oke (2004) hay cuatro aspectos claves que inciden sobre el fenómeno isla de calor: estructura urbana (dimensiones de los edificios), cobertura urbana (proporción de construcciones, vegetación y agua), materiales (naturales y construidos) y metabolismo urbano (calefacción, agua y contaminantes por actividades humanas) (Alberti, 2008; Oke, 2004). La geometría de los edificios y las calles pueden crear cañones urbanos, en donde la absorción de la radiación solar aumenta. El cañón creado por los edificios reduce la velocidad del viento y por lo tanto reduce la cantidad de calor que el aire puede transportar (Oke 1987), alterando los patrones de viento y agravando el fenómeno isla de calor (Baklanov et al. 2017). Por otra parte, la contaminación del aire en las ciudades, absorbe más radiación y también emite más; aumentando la radiación de onda larga y aumentando condensación de nubes (Souza et al. 2016). Los materiales utilizados en construcción almacenan más calor y disminuyen la cantidad de humedad que se evapora (Breuste 2012). El balance de energía difiere significativamente entre coberturas rurales y urbanas (Grimmond and Oke 1998)(Oke 2004). Ambas reciben energía de la radiación, la superficie de la tierra se calienta durante el día y libera el calor durante la noche. En contraste, las coberturas urbanas, tienen una capacidad para almacenar calor más alta,

comparadas con las coberturas naturales. Las coberturas urbanas absorben la radiación solar y la almacenan durante el día, mientras que el calor es liberado durante la noche. Por lo tanto, esta re-radiación de energía solar aumenta la temperatura del aire en las áreas urbanas (Blake et al. 2011).

2.2 Justificación

Por otra parte, se ha visto que aspectos importantes de las áreas urbanas, como densidad de población, y calor antropogénico, entre otros, son usualmente ignorados en la mayoría de los estudios (Chapman et al. 2017b). Otras variables que usualmente no se tienen en cuenta son: morfología urbana, propiedades de la superficie, transporte e industria (Vuckovic et al. 2017). Existe una concentración de estudios sobre el efecto de la urbanización sobre el clima y cambio climático en Europa, Norte América y China, y sin embargo, hay un gran vacío de información en las regiones más vulnerables al cambio climático: África y Sur América (Chapman et al. 2017b). Es necesario seguir evaluando diferentes configuraciones entre materiales de alto albedo y sus efectos sobre el microclima (Salata et al. 2015). La mitigación de la isla de calor y la mejora del ambiente urbano termal, es crucial para el desarrollo sostenible de la economía urbana y la protección del ambiente. Por otra parte, es vital para crear condiciones de vida sostenibles para todo tipo de residentes urbanos (Qiu et al. 2017). La intensidad del fenómeno islas de calor pueden crear problemas de salud pública y aumentar la mortalidad (IPCC 2007). Por esto, es necesario a través de la interdisciplinariedad, lograr involucrar los aspectos ambientales que inciden sobre el confort humano en la planeación urbana.

Teniendo en cuenta la naturaleza de los ecosistemas urbanos; densamente poblados, no lineales, abiertos, dominados por humanos con patrones, procesos y disturbios ecológicos diferentes (Quetglas et al. 2006, Alberti 2008) se puede considerar que los métodos estadísticos tradicionales no representan completamente la variación del fenómeno Isla de Calor en un contexto urbano. Este estudio propone un enfoque desde la inteligencia artificial a través de las redes neuronales artificiales, dado que el fenómeno Isla de Calor, ha sido considerablemente abordado desde diferentes perspectivas de la estadística tradicional y tiene diferentes limitaciones. Las redes neuronales artificiales aprenden sobre el ambiente, simulando las actividades del cerebro animal y son óptimas herramienta para estudiar ecosistemas (Zhang 2010). Son capaces de establecer relaciones no lineales entre diferentes variables, obtienen mejores resultados en predicciones que los métodos tradicionales, incluso con altas cantidades de valores atípicos y mucha incertidumbre (Quetglas et al. 2006); haciéndola una herramienta prometedora para el estudio del fenómeno en Bogotá D.C

1.3 Propósito

Es importante abordar esta problemática, ya que está situada donde la mayoría de la población humana se concentra. Las ciudades actualmente tienen una tendencia a seguir creciendo; el fenómeno isla de calor está relacionado con la manera en la que construimos y habitamos los espacios. Conocer y comprender el comportamiento del

fenómeno isla de calor en Bogotá D.C sirve para mitigar y prevenir que se desarrolle en un futuro. Por otra parte, las redes neuronales artificiales son una herramienta que destaca por su buen desempeño utilizando datos de sistemas abiertos, con alta incertidumbre y no lineales. Lo que propone una oportunidad para entender el fenómeno isla de calor desde otra perspectiva.

El propósito de esta investigación es construir y analizar una red neuronal que evalúe las diferentes variables relacionadas con el fenómeno isla de calor en Bogotá D.C. Evaluar las capacidades que tiene la red para predecir y tener en cuenta sus resultados para aportar a la planeación de la ciudad con el fin de mitigar y prevenir el fenómeno en un futuro. Por último, se quieren considerar las redes neuronales como una posible herramienta dentro de los ecosistemas urbanos y evaluar su desempeño y manejo.

3. Objetivos

3.1 General:

Diseñar una red neuronal que permita evaluar el fenómeno isla de calor a partir de la información disponible para las diferentes localidades de la ciudad de Bogotá D.C.

3.2 Objetivos específicos:

- (1) Analizar las variables disponibles y sus pesos sinápticos en relación con el fenómeno isla de calor.
- (2) Evaluar el desempeño de la red a través de las métricas del error máximo absoluto, el error relativo absoluto y el coeficiente de determinación para las predicciones y proyecciones realizadas por la red neuronal artificial.
- (3) Evaluar la red neuronal diseñada como herramienta para las islas de calor y la ecología.

4. Marco teórico

A continuación, se presentan los conceptos teóricos que se tuvieron en cuenta para la realización de este estudio. Se utilizaron conceptos dentro de la Ecología Urbana, Climatología y las propiedades de las superficies urbanas.

4.1 Ecología Urbana

La ecología es el estudio de los procesos que inciden sobre la distribución y abundancia de los organismos, la interacción entre organismos y las interacciones entre organismos y los recursos. Algunos científicos naturales definen la ecología urbana como ecología, pero limitada a los paisajes urbanos o urbanizados (Breuste 2012). Breuste (2012), plantea que la ecología urbana integra conocimientos básicos y aplicados de la investigación de ciencias sociales y naturales para explorar y comprender múltiples dimensiones de los ecosistemas urbanos. Según Marina Alberti (2008), la ecología urbana es el estudio de las maneras en las que los sistemas ecológicos y humanos han evolucionado juntos, en regiones urbanizadas. Sugiere, por lo tanto, que esta es una ciencia emergente de la integración de diferentes disciplinas, que nace de la necesidad y curiosidad por comprender estructuras y funciones ecológicas de las ciudades (Breuste

2012). Las ciudades son regiones urbanizadas, sistemas complejos naturales habitados por humanos, como agentes dominantes. Los humanos transformamos los paisajes; alterando las condiciones, procesos y dinámicas ecológicas. La urbanización, entre otros, afecta la composición de especies, el sistema hidrológico, modifica los flujos de energía y los ciclos de los nutrientes (Alberti 2008).

Dentro de la ecología urbana existe la ecología en las ciudades; que estudia los hábitats y organismos dentro de las ciudades. De otro lado, está la ecología de las ciudades, que se enfoca en estudiar las áreas urbanas desde una perspectiva de un sistema ecológico (Grimmond and Oke 1999), en la que este enfocada este estudio. El manejo de estos sistemas requiere un entendimiento de los mecanismos que relacionan los procesos humanos con los ecológicos y el control sobre sus dinámicas y evolución. El cambio es una propiedad inherente de los sistemas ecológicos (Alberti 2008) y la intervención humana a través del uso de la tierra ha cambiado la frecuencia de los disturbios y sus intervenciones en cantidad y calidad, afectando los ecosistemas urbanos (Breuste 2012). Continuando, la capacidad que tienen las ciudades para adaptarse a estos cambios las hace, más o menos, sostenibles a un largo plazo (Alberti 2008).

Los impactos de la urbanización sobre los ecosistemas han sido ampliamente estudiados durante la última mitad del siglo 20 (McDonnell et al. 1993). Mayoría de los estudios tienen que ver con la ecología en las ciudades y no de las ciudades, donde muchas veces se obvian aspectos como la económica, políticas públicas y sociología (Alberti 2008). Los modelos ecológicos de los ecosistemas urbanos simplifican los procesos humanos. Al estudiar la manera en la que los procesos humanos y ecológicos interactúan, debemos considerar que hay muchos factores que actúan simultáneamente a niveles diferentes. Si únicamente relacionamos modelos tradicionales disciplinarios de sistemas humanos y ecológicos, es probable que las dinámicas del sistema sean mal interpretadas, pues sus interacciones pueden no ser tenidas en cuenta (Alberti 2008). Es importante, en este contexto, comprender que la forma física de las ciudades puede ser únicamente interpretada entendiendo que el uso del suelo es un proceso continuo, que involucra las actividades humanas. El metabolismo de las ciudades depende de las actividades humanas y está relacionado con la concentración y densidad de las personas y sus procesos económicos (Breuste 2012).

En específico, al cambiar la cobertura de vegetación por cemento y edificios, las superficies urbanas disminuyen la cobertura original e introduce nuevos materiales como el concreto, asfalto, piedras, vidrio etc. que no están biológicamente activos. Un nuevo mundo físico es creado, por lo tanto, un nuevo ambiente ecológico con diferentes condiciones y procesos (Oke 1987).

4.2 Climatología:

En los últimos años el clima ha recibido especial atención en términos de investigación y aplicaciones; se ha vuelto un tema de discusión política y publica por sus impactos en el bienestar humano (Breuste 2012).

Las ciudades no son ajenas a la variación climática, incluso muchos consideran que son

más vulnerables a las oscilaciones de la circulación atmosférica. Estas oscilaciones son debidas a temporadas que ocurren varias veces al año, usualmente son predecibles y tiene impacto sobre la temperatura y precipitación, en regiones específicas. Las variaciones, aunque tengan una ubicación específica, tienen la capacidad de afectar la temperatura y precipitación de regiones lejanas a través de las tele-conexiones. La variación climática puede tener varios impactos; como afectar la frecuencia e intensidad de extremos de temperatura y precipitación. Por lo tanto, es importante que las ciudades reconozcan los riesgos creados por los impactos del clima asociados con el cambio climático (Blake et al. 2011).

La variación climática natural tiene cierto nivel de predicción, lo que hace que las ciudades se puedan preparar para eventos extremos. Aun así, mayoría de las ciudades en vía de desarrollo no tienen la capacidad de predecir o adaptarse. Por otra parte, si bien las proyecciones de los modelos climáticos están mejorando aún no es posible predecir con total certeza y hay muchísimos errores. Es importante tener en cuenta también, que, con el cambio climático, los patrones de variación climática naturales se han visto alterados en termino de intensidad, frecuencia y duración; probablemente sigan variando aún más. Si los nodos de variación se mantienen, el cambio climático puede afectar los patrones de tele-conexiones que inciden sobre los patrones de clima regionales. El cambio climático y la variación climática pueden interactuar de maneras complejas e impredecibles; esto se puede manifestar en cambios en los patrones de vientos, que alteren tele-conexiones regionales (Blake et al. 2011).

Las predicciones indican que uno de los fenómenos que más impacto tendrán sobre las ciudades del mundo es ENSO (Fenómeno el Niño y Niña). Todavía existe mucha incertidumbre frente a cómo las condiciones de ENSO cambiarán con el aumento de la temperatura. Aunque algunos estudios predicen que mientras aumenten las concentraciones de gases de efecto invernadero, ENSO, será más dominante, aún hay mucha incertidumbre(Blake et al. 2011).

El proceso de urbanización crea cambios radicales en las superficies y las propiedades atmosféricas de una región. Las principales causas de un cambio en el clima urbano son: (1) el cambio de suelo natural por superficies selladas, artificiales y con una estructura 3D, (2) la reducción en las áreas cubiertas por vegetación, (3) reducción de emisiones de ondas largas de las superficies, por los cañones creados por edificios y (4) emisiones, lixiviados y residuos sólidos que generan contaminantes atmosféricos y calor (Paul and Meyer 2001). Se altera la radiación, la humedad, las características aerodinámicas, propiedades térmicas y por lo tanto altera los balances solares e hídricos naturales (Oke 1987, Grimmond and Oke 1998, 1999) . Las principales diferencias entre los sistemas de clima urbano y clima rural son: (1) el área urbana tiene muchas superficies aerodinámicas ásperas, que incide sobre la turbulencia vertical y los vientos, (2) tiene proporciones diferentes de radiación y calor debido a las propiedades físicas de los materiales utilizados, (3) usualmente es altamente tridimensional y por lo tanto es complejo el intercambio de procesos con los bordes, y (4) es una fuente de emisiones por tráfico, industrias, calefacción y aire acondicionado (Breuste 2012). Por lo tanto, las áreas urbanas demuestran claros cambios en los patrones climáticos. (Grimmond and Oke 1998) (Oke 1987).

La atmosfera urbana se puede dividir entre la capa limite urbana y el canopy urbano. La capa limite urbana, es un fenómeno a la meso escala local en donde las características son dictadas por la naturaleza urbana. Debajo del techo, existe la capa de canopy urbano, que es producida por procesos a micro escala, que ocurren en las calles (cañones) y construcciones (Oke 1987, Grimmond and Oke 1998).

4.2.1 Fenómeno Isla de Calor

El fenómeno isla de calor es una de las observaciones más antiguas de la climatología, en 1820 fue descrito por primera vez. Este se describe como un aumento en la temperatura en las regiones urbanas comparado con los lugares rurales alrededor. El fenómeno isla de calor puede alterar patrones climáticos locales, regionales y hasta escalas continentales. Por ejemplo, puede alterar patrones de lluvia locales y llegar a inducir tormentas (Wilson 2011). Se ha observado que el fenómeno isla de calor esta relacionado con el tamaño de la ciudad, su población y densidad (Oke 1987) y que ocurren durante la tarde, la noche y temprano en la mañana, las temperaturas urbanas se intensifican en la tarde y se mantienen altas durante la noche (Wilson 2011).

Las islas de calor tienen grandes repercusiones biológicas, económicas y meteorológicas. El calor urbano incide sobre la floración y crecimiento de diferentes plantas en las ciudades (Touchaei et al. 2016). Debido a las elevadas temperaturas las temporadas de crecimiento son más largas, y pueden llegar a atraer diferentes aves ya que su clima es más favorable. Pero para los humanos, un aumento de temperatura puede llegar a ser estresante e incluso un riesgo para su salud. Económicamente las islas de calor son beneficiosas ya que reducen el uso de calentadores, pero pueden aumentar el consumo de aire acondicionado (Oke 1987).

La urbanización usualmente se traduce en superficies impermeables, a los que el agua de la lluvia no puede infiltrar. El calor del fenómeno isla de calor viene de la radiación del sol, cuando se calientan las superficies y se almacena el calor. No todas las superficies impermeables tienen las mismas propiedades térmicas. Algunos autores consideran que todas las superficies que no son impermeables, y que algunas pueden ser consideradas funcionales, como la vegetación, aunque no tengan las mismas propiedades, si tienen propiedades totalmente diferentes a la de las superficies impermeables. Por lo tanto, céspedes, bosques, ríos, riachuelos, lagos, humedales pueden tener impactos positivos sobre la regulación de las temperaturas en las ciudades. (Wilson 2011)

Usualmente, el aire en el canopy urbano es más caliente dentro de la ciudad que por fuera de esta, esto se conoce como el fenómeno isla de calor. El fenómeno puede variar en forma, tamaño, tiempo y espacio debido a diferentes factores meteorológicos, características urbanas y ubicación (Oke 1987). El aumento de temperatura se debe al balance de energía de la superficie, se da por cambio de radiación de ondas cortas ondas largas emitidas en la noche (Blake et al. 2011). La radiación de onda corta, es la luz visible que contiene mucha energía, mientras que, la onda larga contiene menos energía. La energía solar entra a la atmosfera en ondas cortas, en luz ultravioleta y luz visible. Allí, las nubes y superficies absorben esta energía, calentándose y posteriormente emitiéndola en radiación de ondas largas. La tierra emite radiación de ondas largas ya

que es más fría que el sol y tiene menos energía disponible para liberar (Landsberg 1981).

Frente a la onda corta, el albedo de una superficie es la propiedad de reflectividad que una superficie tiene para la luz visible, este se mide de 0 a 100. Usualmente, el albedo dentro de las ciudades es más bajo que las superficies naturales, ya que las segundas tienden a ser más oscuras. Entre más bajo sea el albedo, más eficiente es la absorción de la radiación de onda corta, por lo tanto, se calienta y almacena más calor la superficie. Entre más altos los edificios más profundos son los cañones urbanos, que tienen reducida vista al cielo e impide que se de el proceso de enfriamiento radiativo de ondas largas. La geometría vertical también incide sobre los vientos, reduciendo la ventilación y el enfriamiento de las superficies (Breuste 2012).

Las islas de calor aumentan la precipitación y la probabilidad de inundación ya que: (1) contribuyen al aumento de las corrientes de aire, lo que desarrolla precipitación convectiva. (2) Disminuye la velocidad de los vientos, aumentando la duración de las tormentas y (3) crea sitios de nucleación para las nubes permitiendo el estancamiento de los contaminantes aerosoles (Blake et al. 2011).

La duración e intensidad de las islas de calor pueden variar. Usualmente, estas pueden crear inestabilidad térmica; creando dos regiones: una de presión alta y otra de presión baja, permitiendo el movimiento del aire de los lugares de alta presión a los de baja presión, siendo los de alta presión aquellos lugares cercanos a la superficie de la tierra. Una vez, la masa de aire caliente asciende, reduciendo la presión en el lugar que del cual se desplaza, la densidad del aire es menor en los lugares cercanos a superficies. Sin embargo, las masas de presión alta logran compensar este movimiento. El vapor de agua en la masa se condensa al llegar a zonas con menor temperatura y se crea una tormenta. Es importante recalcar que, no toda precipitación es creada por islas de calor, también existen patrones climatológicos responsables (Wilson 2011). Se concluye, que el fenómeno isla de calor puede crear corrientes de viento verticales que favorecen la precipitación convectiva (Blake et al. 2011).

Por otra parte, la isla de calor puede tener un impacto en la contaminación aérea, ya que debido a las emisiones la calidad de aire es menor en las áreas urbanas que en las rurales. Se conoce que los lugares de alta densidad poblacional y alta actividad económica son responsables de alrededor del 40% de las emisiones de gases con efecto invernadero (Blake et al. 2011). La capa de inversión creada sobre las islas de calor impide la difusión de los contaminantes, aumentando los niveles de contaminación locales. Esto conlleva a la lluvia ácida. En el 2003, se demostró que, en Shanghái, este fenómeno causaba un aumento del pH promedio del vapor de agua, creando lluvia ácida la cual aumentó de 5.21% a 16.7% con la presencia de las islas de calor. (Blake et al. 2011).

Las áreas urbanas tienen una menor humedad dado que sus superficies no retienen el agua y las altas temperaturas de las mismas hacen que esta se evapore más rápido. Por el contrario, la humedad en suelo rural es mucho mayor, permitiendo menores temperaturas y una evapotranspiración que se da de manera más lenta. Los ciclos diarios

de humedad en el gradiente urbano-rural se pueden ver afectados por el rocío, estabilidad atmosférica y las heladas que pueden secar el aire rural durante la noche (Blake et al. 2011). así aumentando la humedad urbana en la noche (Oke 1987).

4.3 Propiedades de las superficies

Hay tres elementos que inciden sobre la temperatura urbana a una escala local: edificios, espacios verdes o cobertura verde y pavimento (Wong et al. 2009). Por otra parte, el planeamiento y diseño de los diferentes barrios en las ciudades, la distribución de edificios e industrias puede reducir de 60 a 90% las emisiones del CO₂ (Yamaguchi et al. 2007).

4.3.1 Superficies Urbanas: Edificios, cemento, asfalto

Los materiales utilizados en las superficies del suelo también tienen un impacto sobre la temperatura. Las superficies urbanas tienden a ser masivas en las ciudades; calles, parqueaderos, y edificios. En los diseños urbanos convencionales, las aceras ocupan de 16% a 23% (Gago et al. 2013). Estos tienden a cambiar radicalmente el ambiente urbano, haciendo que la temperatura en las ciudades aumente de 5 a 10°C, en comparación con los lugares rurales alrededor (Wilson 2011).

Muchas de las ciudades en Norte América y Europa muestran patrones de isla de calor en función de la densidad de la población humana. Estos estudios también resaltaron que el tipo de arquitectura incide sobre el fenómeno isla de calor. El factor de visibilidad del cielo es la cantidad de cielo visible desde las calles aledañas a los edificios, se utiliza para estimar el flujo de viento y energía que transita por los cañones (calles) (Wilson 2011). Los edificios altos y que reflejan luz, disminuyen el factor de visibilidad del cielo en varias ciudades americanas, mientras que, en las ciudades de Europa, no.

La ubicación de un edificio modifica el ambiente a través de radiación, condiciones térmicas, humedad, y condiciones aerodinámicas. El efecto más importante es la disminución de recepción de radiación solar de las áreas que están en su sombra, y un aumento local en la recepción de luz, por la reflexión de las paredes en otros lugares. Así, los edificios producen reducción del enfriamiento neto de ondas largas, por espacio reducido para el factor de vista al cielo. El balance hídrico al rededor del edificio es modificado por la variabilidad espacial en la precipitación, el drenaje del suelo y la evaporación. El mayor impacto se da en el flujo de aire (Oke 1987).

Los materiales usualmente utilizados en construcciones urbanas densas impermeabilizan la superficie, permitiendo mayor almacenamiento calor. Una geometría de bloque, formada por edificios, posibilita el atrapamiento de radiación y estancamiento del aire. Así mismo, estructuras que son consideradas 'ásperas' disminuyen la velocidad del viento y la capacidad de convección, donde el calor y agua son liberados como un "producto secundario" (Memon et al. 2008, Bernard et al. 2017) . Es importante también tener en cuenta que con las emisiones y la contaminación, los edificios afectan la transferencia de radiación, haciendo que los contaminantes se estancuen y faciliten la lluvia ácida o la creación de núcleos para la precipitación (Oke 1987, Grimmond and Oke

1998) .

4.3.2 Albedo

El albedo de las superficies es una propiedad fundamental que puede ser fácilmente alterada. Esta determina directamente la absorción de una superficie, dado un input de energía solar. El albedo regula la absorción de ondas cortas de la superficie. Esto limita el balance de energía en la superficie y el balance interrelacionado con agua, por lo tanto, controla la humedad, la temperatura de la superficie, el aire inmediato y las capas de suelo. Manipular o alterar en albedo tiene una reacción en el clima. (Grimmond and Oke 1998)

La distribución de la temperatura en las áreas urbanas está afectada por el presupuesto de radiación urbana. La radiación solar incidente en superficies urbanas es absorbida y transformada en calor sensible. Los techos, superficies de edificios, calles, plazas y etc. forman una gran masa donde el calor se acumula. Este calor es emitido después al ambiente en forma de radiación de onda larga. Por otra parte, la intensidad de la onda depende del porcentaje de superficie visible al cielo y en las características de los materiales como: albedo, emisividad, e inercia termal. (Gago et al. 2013)

(Taha 1997) demostró que el uso de materiales con valores altos de albedo disminuye la radiación solar que se absorbe por edificios y superficies urbanas. Al mantener estas superficies más frías, la intensidad de la radiación de onda larga se redujo(Gago et al. 2013). También se ha visto que un mejor aprovechamiento de las radiaciones de onda corta puede ser logrado a través de la manipulación de la geometría de las superficies receptoras (Gago et al. 2013).

4.3.3 Cobertura Vegetal y Evapotranspiración

Diferentes investigaciones concluyeron que los parques y las áreas verdes en zonas urbanas ayudan a mitigar el fenómeno isla de calor. Además de disminuir el consumo de energía en verano, también reducen los cambios en las temperaturas generados por los materiales, ya que logran estabilizar las fluctuaciones de temperatura en los materiales. Aun así, no es claro como los parques afectan la formación de las islas de calor, ya que depende altamente del tamaño del parque, y las condiciones de la radicación. (Blake et al. 2011)

La cobertura vegetal tiene como mayor aporte la evapotranspiración. La evapotranspiración es un proceso clave y necesario dentro de las ciudades. Este consiste en la pérdida de agua a través de vapor, liberado por la planta. La evapotranspiración es la evaporación de agua líquida de las plantas. Las altas temperaturas aceleran la transpiración de las plantas, agua que usan y pierden mientras crecen. Esta limitada dependiendo de la cantidad de agua disponible y la temperatura. Ocurre cuando una superficie llega a una alta temperatura, que logra evaporar el agua si la humedad relativa es menos del 100%. La energía, en la evapotranspiración usualmente viene de la luz solar, y depende de la radiación solar (Gago et al. 2013). La evapotranspiración está ligada con productividad primaria, esta es la medida utilizada

para calcular que tanto carbón fijan las plantas durante la fotosíntesis, también se utiliza para evaluar las condiciones de las comunidades de plantas (Wilson 2011).

La evapotranspiración tiene un efecto refrigerante sobre las hojas y la temperatura. Esto es útil en las ciudades ya que contra arresta el calor almacenado por los materiales impermeables como el asfalto y concreto, que no retienen agua para la evapotranspiración. Al contrario, estos materiales rápidamente absorben el agua, o la redireccionan a desagües y almacenan calor cuando están expuestos a la radiación solar (Gago et al. 2013).

Por otra parte, la sombra creada por los arboles también ayuda a bajar la temperatura de la atmosfera, al interceptar radiación solar y prevenir que la superficie del suelo y el aire se caliente. Diferentes tipos de coberturas tienen diferentes efectos sobre la temperatura. (Gago et al. 2013).

Por último, la evapotranspiración se asocia con el mantenimiento de la población humana, ya que muchos de los productos que se consumen y utilizan para la el desarrollo, comercio y alimentación vienen de diferentes tipos de plantas. En varios estudios también relacionan la evapotranspiración con la riqueza de especies, teniendo una relación con la diversidad biológica. (Wilson 2011)

4.4 Redes Neuronales:

Las redes de neuronas artificiales inicialmente fueron desarrolladas para modelar funciones biológicas. Funcionan como maquinas inteligentes; piensan y trabajan de la misma manera en la que lo hace el cerebro de un animal. Logran aprender de la experiencia mejor de lo que lo haría un computador convencional permitiéndoles resolver problemas computacionales difíciles. Actualmente, son ampliamente utilizados en el reconocimiento de discurso e imagen. En biología, mayoría de las aplicaciones han sido utilizadas en medicina y biología molecular (Sánchez Camperos and Alanís García 2006).

Debido a su complejidad, no linealidad e incertidumbre de los sistemas ecológicos, los modelos matemáticos simples no siempre describen los sistemas de manera integral. La ecología computacional es la ciencia que concentra la investigación ecológica, construcción, aplicación de teorías y métodos que permitan la mejor identificación de los sistemas ecológicos (Zhang 2010).

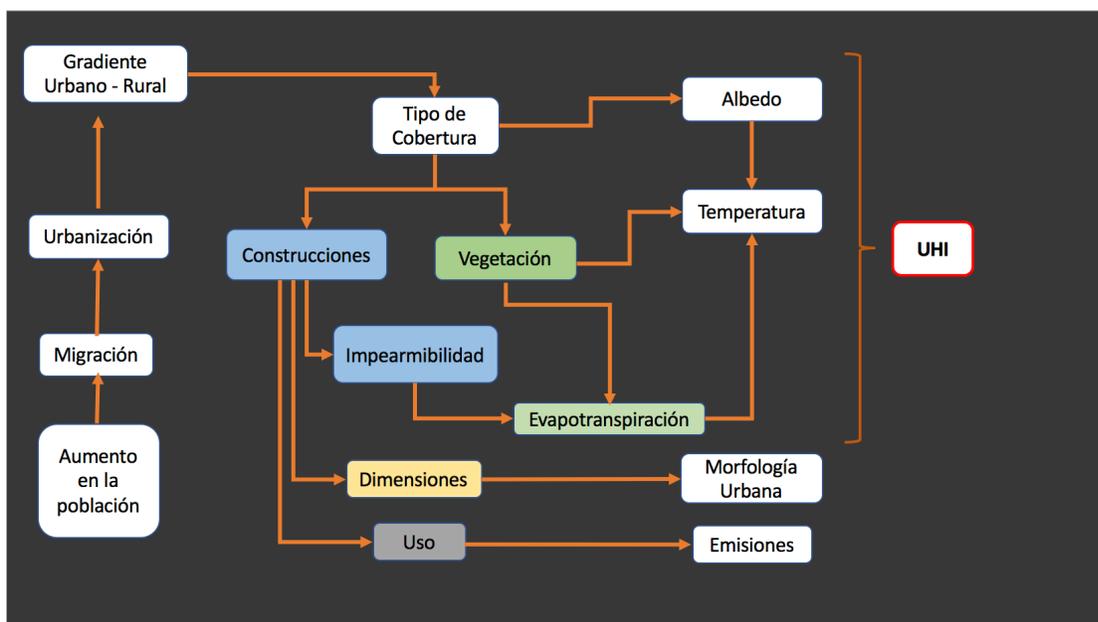
Desde 1970 ecólogos han logrado entender ecosistemas a través de modelos mecánicos. La efectividad y validación de los modelos mecánicos ha disminuido mientras la complejidad del modelo aumenta. Puede tener como resultado modelos poco concretos, inestables y con baja confianza. Por otra parte, las relaciones ecológicas son altamente no lineares, y por lo tanto no podrían ser descritas razonablemente por modelos clásicos, incluyendo ambos mecánicos, o empíricos (Lek and Gue 1999, Zhang 2010).

Las redes artificiales de neuronas han sido reconocidas universalmente como funciones que aproximan las relaciones ecológicas complejas y no lineales (Zhang 2010). Tienen la ventaja de que son modelos automáticos para sintetizar y analizar input-output. Muchos estudios con aplicaciones ecológicas han sido realizados en los últimos 10 años. Las redes neuronales han sido utilizadas para clasificar, reconocer, y predecir problemas ecológicos que han sido comparadas con varios métodos de análisis convencional (Lek and Gue 1999, Quetglas et al. 2006). Comprobado que son más efectivos que ecuaciones diferenciales. Fueron superiores a modelos lineales, modelos aditivos generales, y árboles de regresión. También tuvieron resultados más acertados que regresiones logísticas, modelos múltiples discriminantes, y regresiones múltiples en predicciones (Lek and Gue 1999, Zhang 2010). Las redes neuronales no tienen tantas limitaciones y requisitos como otros métodos de análisis estadísticos o aplicación de modelos. Se debe agregar que también presenta uniformidad en el análisis y el diseño y por lo tanto garantiza características precisas (Camperos and García 2006, Quetglas et al. 2006).

Para la construcción de redes neuronales se deben cumplir cuatro reglas básicas de representación del conocimiento (Camperos and García 2006):

- Regla 1: Entradas similares, pertenecientes a clases similares.
- Regla 2: Ejemplos a categorizarse separadamente deben tener una representación muy diferente en la red neuronal
- Regla 3: si una característica es importante, debe existir un gran número de neuronas dedicadas a su representación
- Regla 4: La información de entrada a la red debe incorporarse a la estructura de la red.

Figura 1: Diagrama Conceptual



En la Figura 1, se explica el procedimiento conceptual con respecto a este trabajo. La problemática se basa en el aumento de la población, y el éxito social y económico que han logrado ser las ciudades, como epicentros de desarrollo. Además del aumento en la población, se ha visto a lo largo de los años, y se predice para el futuro, que habrá aun una mayor migración de personas hacia las ciudades. Cuando la densidad poblacional de las ciudades aumenta, hay aumento en el área urbana. Las áreas urbanas están definidas por tener construcciones, importantes vías con alto tráfico y superficies impermeables, entre otros. Estas alteran los ecosistemas, al cambiar totalmente la cobertura original, usualmente vegetal, por coberturas impermeables con diferentes alturas, tamaños y materiales. Es importante entonces, tener en cuenta las propiedades de los tipos de las coberturas en las ciudades y como estas alteran en entorno. Una de las propiedades más estudiadas dentro de la morfología urbana es el tipo de material y su albedo. Ya que este representa el porcentaje de ondas largas reflejadas de nuevo a la atmosfera, aumentando la temperatura. Al tener menos permeabilidad, no solo las probabilidades de inundación son más altas, pero también hay más agua disponible para la evapotranspiración, alterando la precipitación.

5. Antecedentes

Se han realizado múltiples estudios alrededor de los tipos de cobertura y su impacto sobre el micro-clima, específicamente sobre la temperatura. Se ha observado una relación entre el tipo de cobertura y uso de la cobertura con la temperatura del aire; por otra parte, una relación lineal negativa entre la cobertura vegetal y la temperatura del aire (Qiu G. et al, 2017). Existe una relación negativa entre la evapotranspiración y la intensidad del efecto isla de calor (Qiu G. et al, 2017). Por lo tanto, Qiu (2017) prueba que la vegetación tiene un efecto enfriador sobre el fenómeno Isla de calor en mega ciudades subtropicales. A su vez, se han encontrado que entre menos vegetación haya más Islas de calor habrá durante el día y la noche en 10 ciudades en China (Yao et al. 2017). Se ha observado que aspectos importantes de las áreas urbanas, como densidad, y calor antropogénico entre otros, son usualmente ignoradas (Chapman et al. 2017a). Otras variables que usualmente no son tenida en cuenta son morfología urbana, propiedades de las superficie, transporte e industria (Vuckovic et al. 2017). También que hay una concentración de estudios sobre el efecto de la urbanización sobre el clima y cambio climático en Europa, Norte América y China, y si bien hay un vacío de información en las regiones más vulnerables al cambio climático, en las regiones de África y Sur América(Chapman et al. 2017a). Es necesario seguir evaluando diferentes configuraciones entre materiales de alto albedo y sus efectos sobre el microclima (Salata et al. 2015).

La urbanización incide sobre el microclima a través de una cobertura introducida impermeable, estructura espacial compacta, emisiones de contaminantes y modificación de las propiedades físicas de las superficies (Dimitrova et al. 2014). Dimitrova et al. (2014) demostraron que hay una diferencia significativa en la temperatura entre cañones (calles) con vegetación y sin vegetación. Debido a que la vegetación brindaba sombra y evapotranspiración.

Aparicio (2010) expone el impacto del transporte en el ordenamiento de la ciudad en el siglo XX, y plantea cómo se organiza la ciudad, en zonas concéntricas, sectores radiales y núcleos múltiples dependiendo del uso del suelo y diferentes sectores socioeconómicos(Aparicio 2010). Por otra parte, Williams Montoya (2014) hizo una recopilación histórica y caracterización de las influencias y acciones que llevaron a que Bogotá tuviera el ordenamiento urbano actual(Montoya 2014). Por último, en el 2010, se comprobó que existía un fenómeno de Isla de Calor en Bogotá (Angel et al. 2010).

6. Área de estudio

El área de estudio fue la ciudad de Bogotá, ya que presenta el fenómeno Isla de Calor, es la ciudad más habitada y está altamente urbanizada. Bogotá Distrito Capital está ubicada en el centro de Colombia en la parte noroccidental de Sur América. Está ubicada sobre la Cordillera Oriental de la cordillera de los Andes. Según la Alcaldía Mayor De Bogotá, tiene una extensión aproximada de 33 kilómetros de sur a norte y 16 kilómetros de oriente a occidente. Entre las coordenadas: 4° 35'56" y 74°04'51", con la altura entre los 2510 msnm y los 3780 (IDEAM 2012).

Socioeconómico:

Según el Informe Nacional de Calidad Ambiental Urbana (2015), Bogotá presenta una calidad ambiental media, reportando 9/12 indicadores directos. Tiene 3,9m²/habitante, su calidad de aire varía desde 32 μ m/m³ a 81 μ m/m³ (baja); mientras que su calidad de agua superficial está calificada como muy baja (0). Por otra parte, presenta la más alta calificación en el porcentaje de áreas protegidas urbanas incluidas en el POT, con una ejecución del 74%. Únicamente 2% de toda la superficie construida fue/está construida con criterios de sostenibilidad y el 28,40% de los suelos urbanos protegidos, tienen conflicto de uso. El consumo residencial de agua por habitante es 78,32L/habitante*día, y la cantidad de residuos sólidos son ,82kg/habitante*día. Hay 4,5 m² de espacio público por habitante(Ministerio de Medio Ambiente y Desarrollos Sostenible 2015).

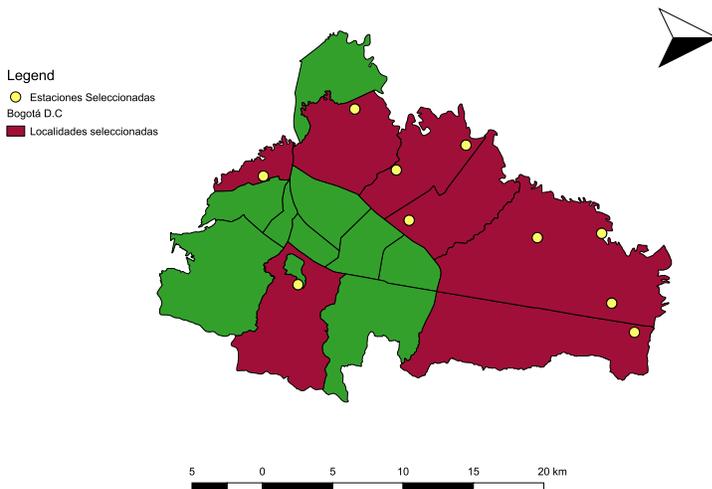
Según el último Censo Inmobiliario Catastral, publicado en el 2018; hay 2,587,226 predios en Bogotá, de los cuales el 98.6% son urbanos. El Área total construida para el 2018 fue 283,240,679 metros cuadrados. Las localidades con mayor área construida son Suba con 39,133,311 metros cuadrados; después Kennedy, Usaquén, Engativá, Fontibón, Santa Fé y por último Tunjuelito con 6,166,706 metros cuadrados. El uso predominante en todas las localidades es residencial (Catastro 2018).

Biofísico:

Bogotá presenta un clima bimodal hacia la sabana y mono-modal hacia los cerros orientales. Hay dos periodos de lluvia, de marzo a mayo y de septiembre a noviembre. La precipitación oscila desde 1.300 mm hasta 550mm. La distribución de la precipitación se concentra cerca a los cerros orientales, río Tunjuelo, La Regadera entre otros, y tiene valores más bajos alrededor de las zonas cercanas al río Bogotá, Ciudad Bolívar y Quiba. La temperatura varía alrededor de los 15 ° C (2008), y oscila entre los 25°C y -4°C (2008). Los meses con temperaturas más bajas son enero y julio y los meses con temperaturas más altas son mayo y noviembre. Se presentan inversiones térmicas y heladas, usualmente concentradas durante los meses secos (diciembre, enero y febrero)(Amaya A. M. J. y Angel C. E. 2008).

Bogotá está ubicada a 2,640 m.s.n.m, y presenta suelos con media a baja capacidad de drenaje, por lo que se encuentran humedales dentro de la ciudad. Por otra parte, debido a su altura y ubicación, aledaño a Bogotá se pueden encontrar Bosques de Niebla y Páramos. Dentro de los límites de la ciudad, están los Cerros Orientales; si bien, cierto porcentaje este poblado por especies no nativas e invasoras, también logra ser un refugio y corredor para la diversidad biológica. Actualmente también se encuentra le reserva Van der Hammen, ubicada al norte de la ciudad con alto porcentaje de urbanización vecina y posible urbanización de esta misma y el Parque Nacional Natural Chingaza, que sule a toda la ciudad de agua (Amaya A. M. J. y Angel C. E. 2008).

Mapa Bogotá D.C: Estaciones y Localidades Seleccionadas

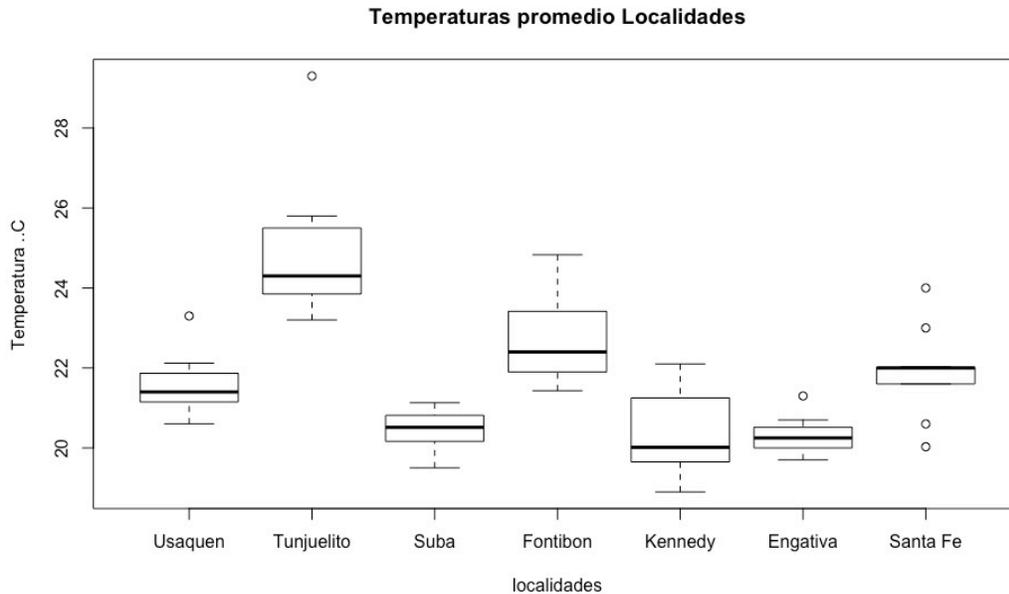


Mapa 1: Localidades y estaciones incluidas en el estudio.

Según el IDEAM, existe una crisis ambiental en Bogotá, está relacionada directamente con los patrones de consumo, índices de pobreza, condiciones de libre acceso a recursos naturales y falta de mecanismos para multar por deterioro ambiental. El crecimiento urbano indiscriminado, ha afectado todos los ecosistemas presentes en la ciudad, y disminuido las áreas verdes y humedales. Lo que más se ha visto afectado por el desarrollo urbanístico han sido los cerros orientales, las rondas de los ríos y pantanos. Por otra parte, en las últimas décadas se ha presentado un desarrollo poblacional significativo, lo que ha generado cambios en el ambiente, que alteran las variables meteorológicas y del clima, como regímenes de carácter térmico, dinámico y del componente hídrico en la ciudad(IDEAM 2012).

En el 2005 se registraron temperaturas medias anuales entre los 12°C y 15° C. La temperatura media máxima tuvo los valores más bajos entre diciembre, enero, febrero y marzo, y los más bajos entre junio, julio y agosto. Esto se da por los vientos alisios, que aumentan su frecuencia y velocidad, disminuyendo la temperatura y bajando la sensación térmica. Por otra parte, las temperaturas extremas ocurren durante diciembre, enero, y febrero, las oscilaciones diarias superan los 25°C; y las temperaturas más bajas se presentan en la madrugada y durante la noche. Curiosamente estos son los días

usualmente considerados como días de buen tiempo, por poca nubosidad, más horas de sol, y menos humedad. Durante estos días, las superficies urbanas se calientan mucho más durante el día, y la radiación se libera durante la noche, bajando las temperaturas.



7. Materiales y métodos

En este segmento, se presenta la metodología utilizada para la realización del estudio. Inicialmente con el diagrama de flujo, presentando las diferentes fases del estudio. El diseño del estudio explica la manera en la que fueron organizados los datos, después se especifica de dónde se obtuvieron y por último se explica los métodos de análisis.

5.1 Diagrama de Flujo

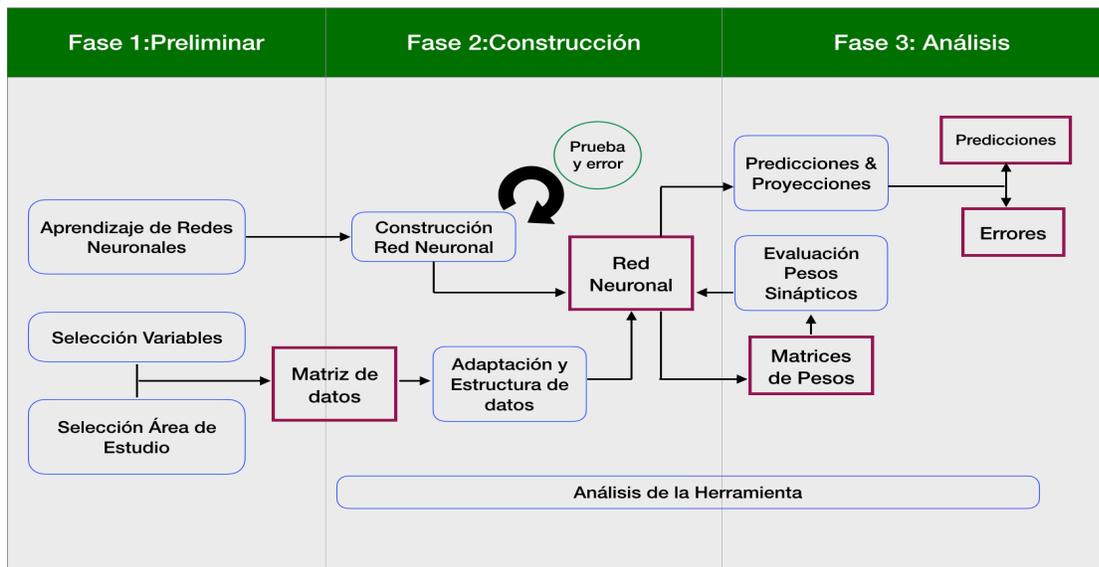


Figura 2: Diagrama de Flujo; 3 fases diferentes, los cuadrados azules representan las actividades y los rojos los productos.

7.1 Diseño del estudio

Este estudio fue diseñado para el análisis de las diferentes variables incidentes sobre la temperatura en diferentes localidades de Bogotá D.C. Las localidades utilizadas fueron limitadas a aquellas con suficiente disponibilidad de datos. En las 7 localidades seleccionadas, se observaron las variables meteorológicas de temperatura media, temperatura máxima y precipitación. También se tuvieron en cuenta variables como altura de las construcciones, hectáreas de vegetación o parques, hectáreas de construcción, densidad de la población, tráfico y emisiones totales; para cada localidad.

El estudio fue enfocado en comparar los diferentes pesos sinápticos asignados a las variables independientes, por la red neuronal después de ser entrenada. Se compararon diferentes arreglos entre las variables independientes y dependientes, basados en la revisión de la bibliografía. Ya que las redes neuronales obtienen mejores resultados que otros métodos, estas proporcionan una mejor representación del sistema (Quetglas et al. 2006). Los datos para el 2017 se organizaron según la fecha, empezando por el mes y después la localidad; para tener en cuenta la variación no solamente espacial de las localidades, pero también de variables climatológicas a lo largo del año. Se modificaron también, los diferentes arreglos de análisis según la bibliografía revisada, para así comparar las diferentes combinaciones de variables y su importancia. Las diferentes combinaciones de variables fueron las siguientes:

Arreglo A: se tuvieron en cuenta las variables que más representan el fenómeno isla de calor según Paul & Meyer 2001: uso del suelo, estructura de los edificios, y tamaño de ciudad (Paul and Meyer 2001). Teniendo en cuenta que la presencia del fenómeno isla de calor puede ser afectado por la ubicación geográfica y regional de las ciudades ((Paul and Meyer 2001). Las variables independientes incluidas son: altura de las construcciones representando la morfología urbana, área de vegetación y área construida.

Arreglo B: Además de las variables incluidas en el Arreglo A, se incluyó también la variable de precipitación. Ya que esta es una variable que también cambia durante el año y está altamente relacionada con el fenómeno isla de calor (Leal Filho et al. 2018).

Arreglo C: En este arreglo, se cambió la arquitectura de la red neuronal con el fin de observar si identificaba cambios en las variables, al tener dos variables dependientes. Las variables dependientes fueron precipitación y temperatura. Las variables independientes fueron las mismas del Arreglo B.

Arreglo D: Para este arreglo se intentó añadir todas las variables relacionadas con el fenómeno isla de calor y aumentar la variabilidad con el fin de obtener mejores resultados. Las variables independientes son: altura de las construcciones, área de vegetación, área construida, precipitación, densidad de la población, tráfico y emisiones de CO₂(Oke 2004).

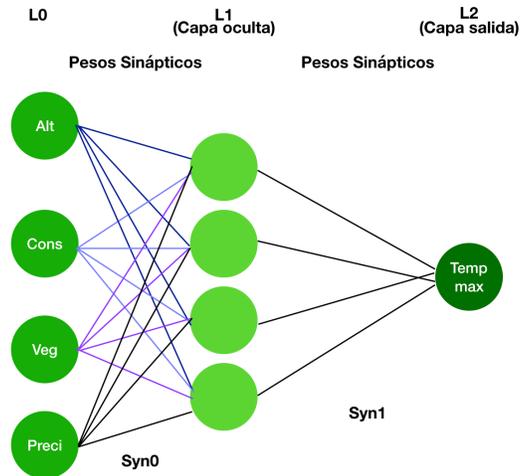


Figura 3: Diagrama de Redes Neuronales: Arreglo B

7.2 Métodos de Recolección de datos

La recolección de los datos se realizó principalmente a través de diferentes entidades públicas nacionales y distritales encargadas del apoyo técnico y científico. Del instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), se utilizaron en total 10 estaciones meteorológicas: Colegio Miguel Antonio Caro (2120669), C. Universidad Agrop UDCA (21206260), Nueva Generación (21206600), Bilbao Máximo (21206630), Apto el Dorado (21205790), Jardín Botánico (21205710), Inem Kennedy (21206560), Colegio Santiago Pérez (21206660) y Col. H Duran Dusan (21206620). De estas estaciones se obtuvieron los datos para el 2017 y 2018 en las variables de precipitación, temperatura promedio y temperatura máxima.

Del Catastro Bogotá, se obtuvo el Censo Urbano para el 2018. Del cual se pudo deducir por localidad: el área construida, área con vegetación y/o parques, uso principal, entre otros. También se obtuvieron mapas de referencia para definir las localidades, el uso del suelo, densidad de la población y altura de las construcciones del IDECA (Infraestructura de datos espaciales para el Distrito Capital).

Por último, los datos sobre las emisiones de CO2 totales, de transporte y CO2 captado por árboles, se obtuvieron del último boletín del Índice para la mitigación del cambio climático en Bogotá, D.C (Planeación 2013). Los datos sobre el tráfico por localidad se obtuvieron a través del informe de Movilidad en Cifras por la Secretaría de Movilidad (Secretaría Distrital De Movilidad 2014).

Para la realización de las proyecciones se tuvieron en cuenta las diferentes proyecciones de los reportes nacionales y distritales como: Nuevos escenarios para el Cambio Climático para Colombia 2011-2100 (IDEAM 2015), Análisis Demográfico y proyecciones poblacionales de Bogotá (Secretaría Distrital 2017) y el Plan Distrital de Desarrollo 2016-2020: Bogotá Mejor Para Todos (Alcaldía Mayor de Bogotá 2016).

7.3 Métodos de Análisis de datos

Las redes neuronales son una adaptación al sistema de las redes neuronales biológicas. Principalmente imitan las excelentes capacidades del cerebro para resolver problemas complejos como: visión, reconocimiento de patrones y aprendizaje. Todas las redes neuronales artificiales tienen: (1) Conocimiento adquirido experimentalmente (input), y (2) sus pesos sinápticos deben variar constantemente (aprendizaje) para considerarse una red neuronal (Camperos and García 2006).

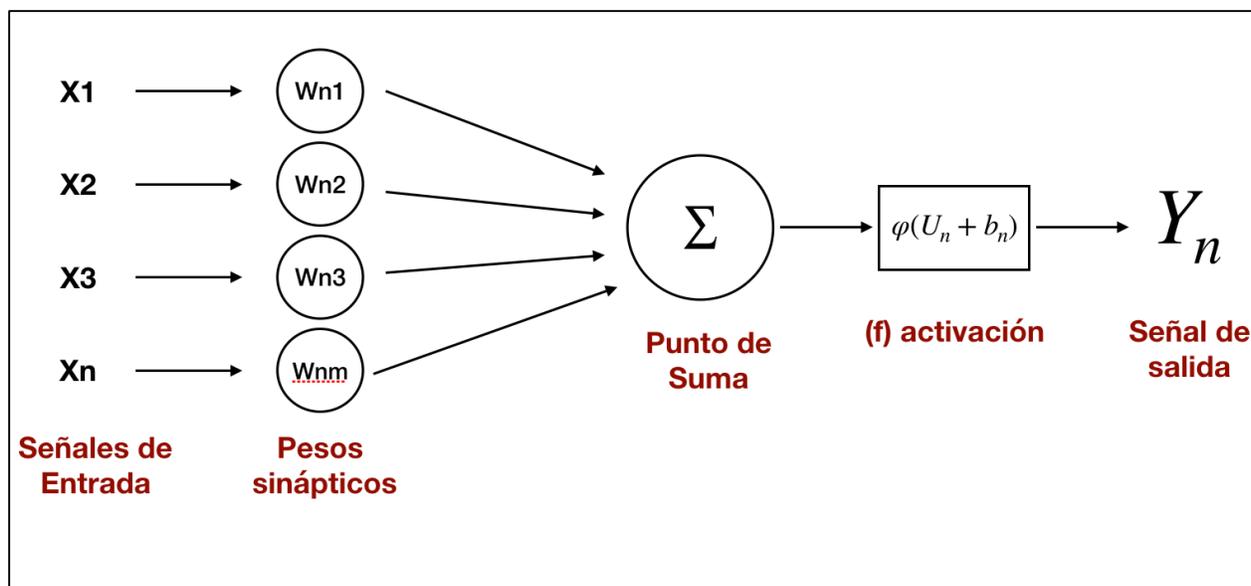
El proceso de aprendizaje consiste en presentar a la red un ejemplo (output, o variable dependiente) para que con base en este, la red neuronal modifique los pesos sinápticos de cada variable independiente (input) de acuerdo con la respuesta esperada. Por lo tanto, la red aprende, y tiene una transformación entrada-salida. También tiene la capacidad de adaptarse ya que sus parámetros o pesos varían en tiempo real. Además, tiene la habilidad de tolerar fallas, ya que trabaja desde una interconexión masiva, una falla de un procesador no altera mucho la operación. La red corre el "modelo" miles de veces realizando pequeñas alteraciones en los pesos, hasta llegar al del menor error posible

La red neuronal se formó a partir de señales de entrada, que fueron multiplicadas después por un vector de pesos sinápticos; que fue alterado constantemente. Después pasaron por una función de activación, para enviar una señal de salida o pasar a la siguiente capa. Los enlaces de conexión o pesos sinápticos son valores que se asignan y van variando para poder conseguir el resultado esperado. Las redes neuronales se pueden explicar a través de la ecuación

$$U_n = \sum_{j=1}^m W_{nj}X_j \quad \text{y} \quad Y_n = \varphi(U_n + b_n)$$

En dónde: x_1, x_2, \dots, x_m son las señales o valores de entrada; $w_{n1}, w_{n2}, \dots, w_{nm}$ son los pesos sinápticos de la neurona. U_n es la combinación de las entradas ponderadas por los pesos sinápticos; b_n es la polarización o la parcialidad. $\varphi()$ es la función de activación y y_n es la señal de salida de la neurona (Camperos and García 2006). También representada en la siguiente imagen.

Figura 4: Diagrama Red Neuronal (Adaptado de (Camperos and García 2006))



Las redes neuronales representan el conocimiento en la manera en la que acumulan información y en sus modelos o procedimientos. Las redes neuronales construyen un modelo de la interacción con el medio ambiente, y por medio del aprendizaje de relaciones entre la entrada y salida (Camperos and García 2006).

Los pasos para la construcción de una red neuronal artificial son (Camperos and García 2006):

1. Definir el tipo de red y su estructura
2. Definir las dimensiones de entrada y salida (proceso heurístico)
3. Entrenamiento de la red
4. Presentación de ejemplos
5. Aplicación

Arquitectura de redes neuronales:

La red neuronal artificial construida para este estudio es una red multicapa, ya que tiene una capa oculta, en la cual todos los nodos computacionales son neuronas ocultas. Está totalmente interconectada, ya que todos los nodos en la capa de la red están conectados con los nodos de la siguiente capa. Puede ser representada por la Figura 3. En total tiene tres capas; L0, L1 y L2, y la cantidad de neuronas por capa varía dependiendo del arreglo. Las variables de entrada representan las neuronas en la capa de entrada y las variables de salida (temperatura máxima) representa la neurona de salida. Este tipo de arquitectura es comúnmente utilizados en las aplicaciones de redes neuronales en ecología y se considera que es de las mejores arquitecturas para predecir (Quetglas et al. 2006).

Aprendizaje

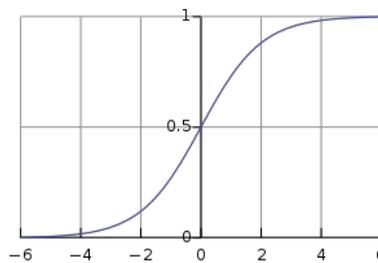
La red neuronal logra aprender al variar los pesos sinápticos y el umbral de polarización.

El entrenamiento es un proceso en los que los pesos se adaptan, debido a la interacción continua con el medio ambiente; en este caso, los datos utilizados. El tipo de aprendizaje se define por la manera en la que se realiza la adaptación a los pesos, para lograr esto es necesario que la red: (1) sea estimulada por la entrada de datos, (2) ajuste sus parámetros y (3) genere una nueva respuesta(Camperos and García 2006).

Función de activación:

Las funciones de activación pueden variar, estas definen la salida de las neuronas en función del potencial de activación, es decir deciden si una neurona se activa o no. Usualmente se escoge entre tres funciones de activación diferentes: La función de escalón o umbral, la función lineal a tramos y por último la función sigmoidea, utilizada en este estudio. La función sigmoidea es la función más utilizada en las redes neuronales, ya que tiene un comportamiento asintótico y es estrictamente creciente (Camperos and García 2006).

$$\varphi(v) = \frac{1}{1 + e^{-av}}$$



Se utiliza esta función representada por la gráfica, también para minimizar el error. En los entrenamientos se corrigen los resultados de la capa L1 a través del delta. El delta se obtiene al multiplicar el error de la capa L1 por la pendiente de la ecuación de activación. Esto hace que se reduzca el error en las predicciones de alta confianza. Todo depende de donde estén ubicados los valores en la ecuación, si toman un valor lejano a 0, en la pendiente; la red neuronal le asignó un valor muy alto o muy bajo. Lo que nos da a entender que hay confianza sobre el valor asignado; por lo tanto, se multiplica por un valor muy bajo. Mientras que, si toman un valor cercano a 0, con baja confianza, serán multiplicados por un valor mucho más alto, para reducir su error. Esto se conoce como retro-propagación, este proceso no optimiza. Pero si modifica los pesos, ya que los resultados de los errores entran a alterar los pesos, para que estos se actualicen.

Optimización:

El descenso por gradiente es un algoritmo de optimización basado en una función convexa que continuamente altera sus parámetros para minimizar una función hasta su mínimo local. Encuentra los valores de los parámetros de una función que minimizan el costo de la función, para este estudio, se aplica sobre la función del error. Se definen los

valores de los parámetros iniciales y de ahí en adelante, se alteran los valores, utilizando cálculo para minimizar la función de costo. Se utiliza ya que nos dice que tan rápido cambian el error cuando los pesos y las polarizaciones varían. Dependiendo del ritmo de aprendizaje, que determina que tan rápido se mueve y evita que nos movamos de un lado a otro en una pendiente de una función convexa. El descenso de gradiente estocástico, actualiza los parámetros para cada ejemplo del entrenamiento, es decir se repite la misma cantidad de veces que la red es entrenada. El método de descenso por gradiente es el más utilizado en redes neuronales (Donges 2018), es el más rápido y también permite llevar un registro detallado del proceso.

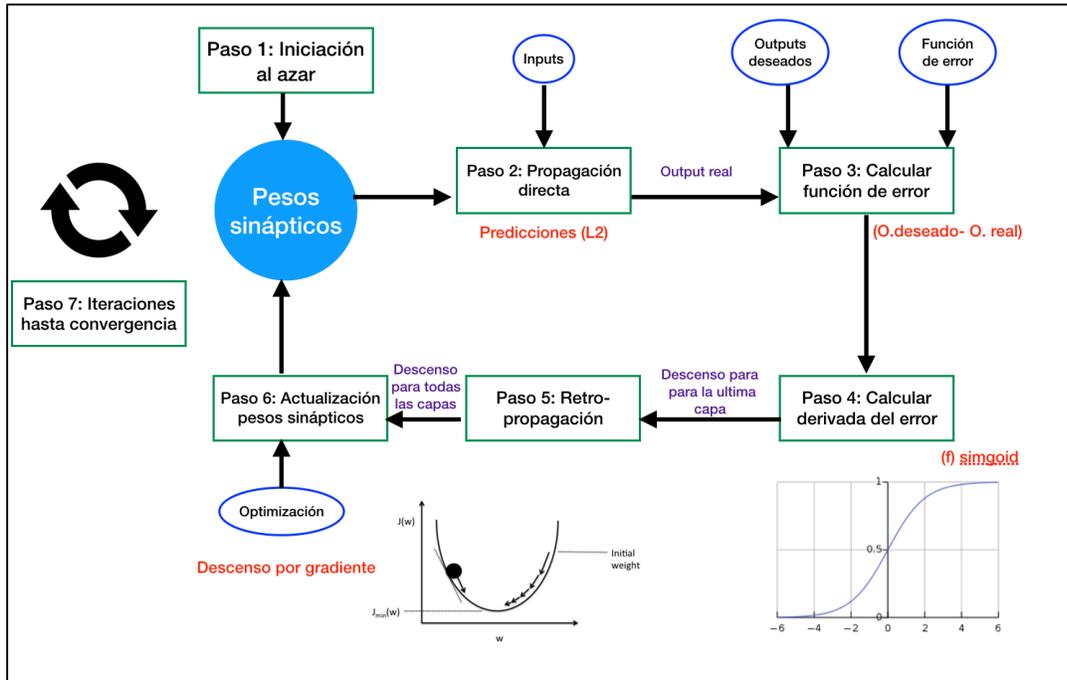


Figura 5: Diagrama construcción de red neuronal por pasos (adaptado de : (Moawad n.d.)

Parámetros:

Tabla 1: Parámetros incluidos en red neuronal.

Variable	Definición
X	Matriz de datos de entrada, cada fila es un ejemplo para el entrenamiento.

y	Matriz de datos de salida, cada fila es un ejemplo. Output Deseado
L0	Primera capa de la red neuronal. En este caso, los datos de entrada.
L1	Segunda capa de la red neuronal, capa oculta.
L2	Capa final de la red neuronal. Predicciones, que se deberían acercar a los datos de y. Output obtenido.
Syn0	Primera capa de pesos sinápticos. Conectando L0 y L1.
Syn1	Segunda capa de pesos sinápticos. Conectando L1 y L2.
L2_error	Calcula el error de las predicciones de L2.
L2_delta	Error de la red neuronal escalado por la confianza. Los errores con alta confianza, fueron corregidos. Permite ver en qué dirección cambiarán los pesos y en qué proporción.
L1_error	Error de la capa oculta. Calculado utilizando los pesos de Syn1 y L2_delta. Define qué tanto contribuyeron los pesos de L1 al error de L2.
L1_delta	Error de L1 escalado por la confianza. Los errores con alta confianza fueron corregidos. Permite ver en qué dirección cambiarán los pesos y en qué proporción.

Para la interpretación de los pesos sinápticos, no se utilizó un Diagrama de Interpretación Neuronal, ya que no se utilizó ningún software para la red neuronal y este método tiene resultados más cualitativos, que cuantitativos (Olden and Jackson 2018). En cambio, la red fue construida en Python 3.6. Por lo tanto, se visualizaron los pesos sinápticos de ambas capas en gráficas. Posteriormente, se utilizó el método del Algoritmo de Garsons, y Aproximación de Pesos de Conexiones (Connection Weight Approximation), recomendado específicamente para la investigación ecológica y el método con mejor desempeño para evaluar los pesos sinápticos desde la capa oculta hacia la capa de salida (Olden et al. 2004, Olden and Jackson 2018). Según este método, para encontrar los porcentajes de importancia relativa, se utilizaron las siguientes ecuaciones (Olden and Jackson 2018):

Contribución de neuronas de entrada a neuronas de salida a través de la capa oculta:

$$C_i = P_{Syn0_i} * P_{Syn1_i}$$

En dónde C, es igual a la contribución. P_{Syn0_i} representa el valor asignado al peso, en cada neurona de la primera capa de pesos sinápticos, entre la capa de entrada y la capa oculta. P_{Syn1_i} es el valor asignado al peso, en cada neurona de la segunda capa de pesos

sinápticos, entre la capa oculta y la capa de salida.

$$rc_i = \frac{|C_i|}{|C_i| + |C_{..n}|} + P_{Syno_i}$$

En donde rc representa la contribución relativa de cada neurona de la capa de entrada a la capa de salida, pasando por la capa oculta.

$$ri_i = \frac{rc_i}{rc_i + rc_n} * 100$$

En la que ri_i representa el porcentaje de importancia relativa de cada variable en cada arreglo.

Proyecciones:

Para la realización de las proyecciones se tuvo en cuenta el arreglo con mejores resultados, comparando los errores y el comportamiento de las predicciones. La adaptación de los datos se realizó utilizando los datos originales y adaptándolos según los datos encontrados en la revisión bibliográfica. Según los documentos previamente mencionados se hicieron las siguientes adaptaciones. Es importante resaltar, que en mayoría de los documentos, se encontraron rangos de variación y por lo tanto se tuvo en cuenta el promedio. Los reportes revisados variaban sus proyecciones desde 2015 hasta 2100. La Tabla 2, muestra los cambios en los datos.

Tabla 2: Variables utilizadas para las proyecciones y cambios realizados.

Variable	Proyección
Altura	+5%
Construcción	+30%
Vegetación	-20%
Precipitación	+25%
Temperatura	+1.4 °C

Se realizaron 3 proyecciones diferentes teniendo en cuenta diferentes porcentajes de calibración y validación. Para la primera proyección se entrenó la red neuronal con 70% de los datos, el otro 30% de los datos fueron utilizados para verificación o ver que tan bien predecía la red. Las otras proyecciones se realizaron con el 50 % de los datos para entrenamiento y el otro 50% para verificación. La última proyección se realizó con el 30 % de los datos para entrenamiento y el 70% para verificación.

Las métricas utilizadas para evaluar y comparar las diferentes proyecciones fueron: Error absoluto máximo (Métrica absoluta), error absoluto relativo (Métrica Relativa) y Coeficiente de Determinación (métrica adimensional) según (Dominguez et al. 2008). Con las siguientes formulas respectivamente:

$$EMA = \max_{i=1}^n (|Observado_i - Output_i|)$$

$$EAR = \frac{\sum_{i=1}^n |Observado - Output|}{\sum_{i=1}^n |Observado - Promedio Observado|}$$

$$C = \left(\frac{\sum_{i=1}^n (Output - Promedio Output)(Observado - Promedio Observado)}{\sqrt{\sum_{i=1}^n (Observado - Promedio Observado)^2 \sum_{i=1}^n (Output - Promedio Output)^2}} \right)^2$$

8. Resultados

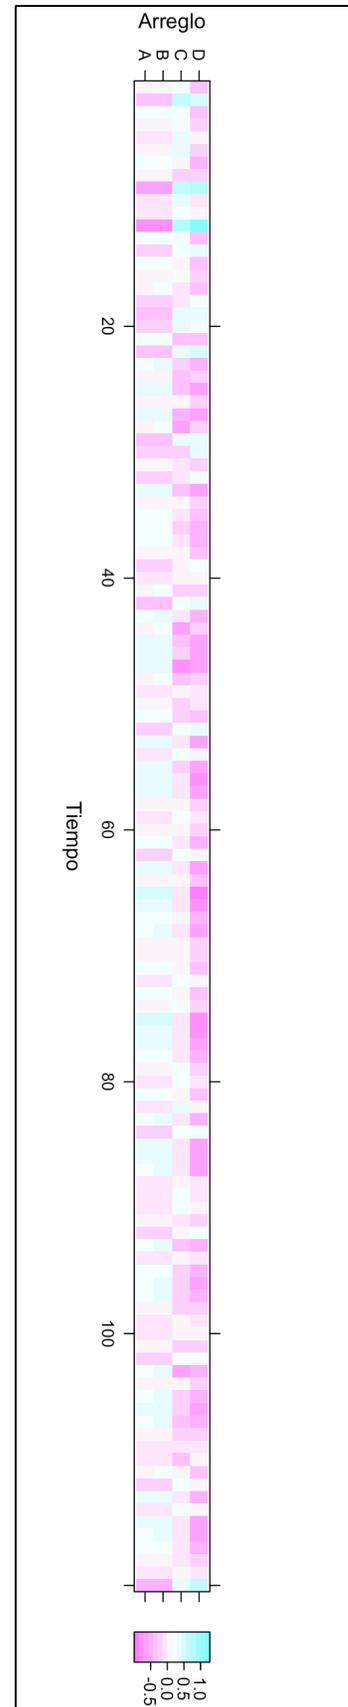
Errores:

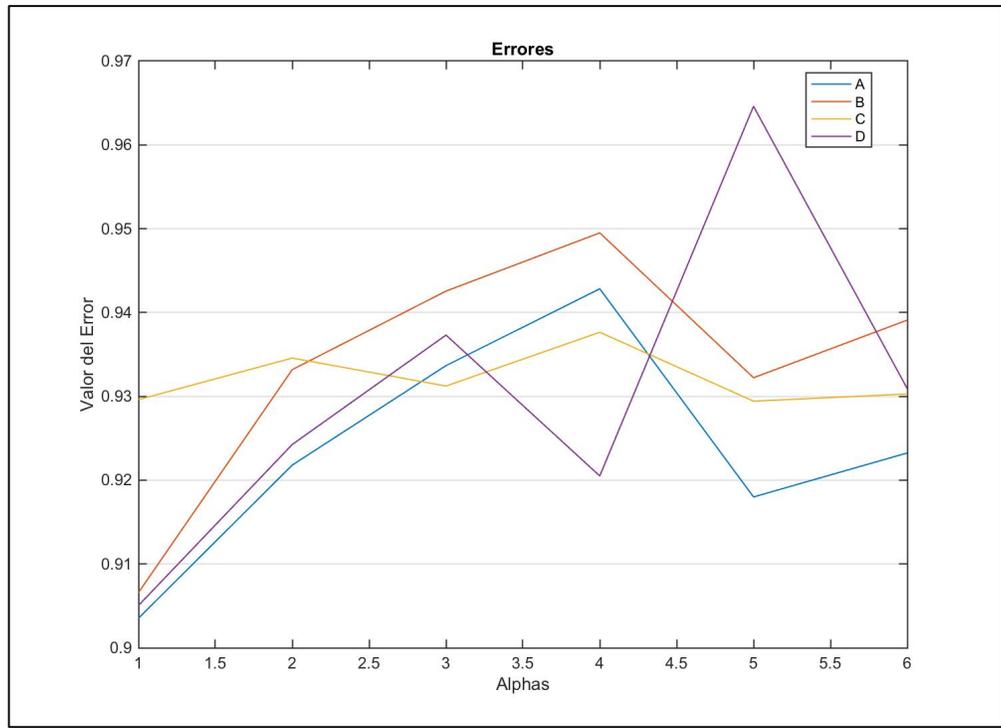
En la Figura 6, se observa una gráfica con los valores de error absoluto total de L2, realizado en el programa R. Studio. Se asignaron diferentes colores a los valores del error. Mientras el valor del error este más lejos del 0, toman colores mucho más fuertes y sólidos. El eje X representa los diferentes arreglos de variables utilizados en el estudio. Mientras que el eje Y representa los 12 meses del año por estación meteorológica. Se tuvieron en cuenta los datos de las 4 matrices de error para cada arreglo, teniendo únicamente en cuenta el error para la temperatura en el arreglo C y no el de precipitación. Cada matriz presentaba 120 filas, representando las 10 estaciones meteorológicas, durante todos los meses del 2018. El error absoluto compara la temperatura registrada en las estaciones del IDEAM, con la que predijo la red neuronal artificial. Es importante resaltar, que el valor graficado no se acerca al delta; ya que en los valores del delta el valor del error, pasa por la función sigmoidea. Esto se hace, para que sean corregidos en la siguiente iteración.

Los valores de error toman valores desde -1 a 1, dependiendo de qué tan lejos están del valor esperado. Si los valores se acercan más a -1, significa que los valores asignados por la red neuronal fueron mucho más altos que los registrados. Al contrario, si los valores de error se acercan a 1, por lo tanto, el valor asignado no fue suficiente.

En la Figura 6, se puede ver que los errores entre los arreglos A y B, son muy similares, ya que no se observa gran diferencia entre los colores de la columna A y B. Por el contrario, si se observa gran diferencia entre las columnas C y D comparada con A y B. Así mismo, entre las columnas C y D. Se observa también que los errores en la columna D se acercan mucho más a -1, que el resto de las columnas. Si bien hay cierta semejanza entre las columnas C y D, los colores en la columna D son mucho más fuertes que los de la columna C.

Figura 6: Errores para cada predicción





Grafica 1: Errores totales de la red neuronal.

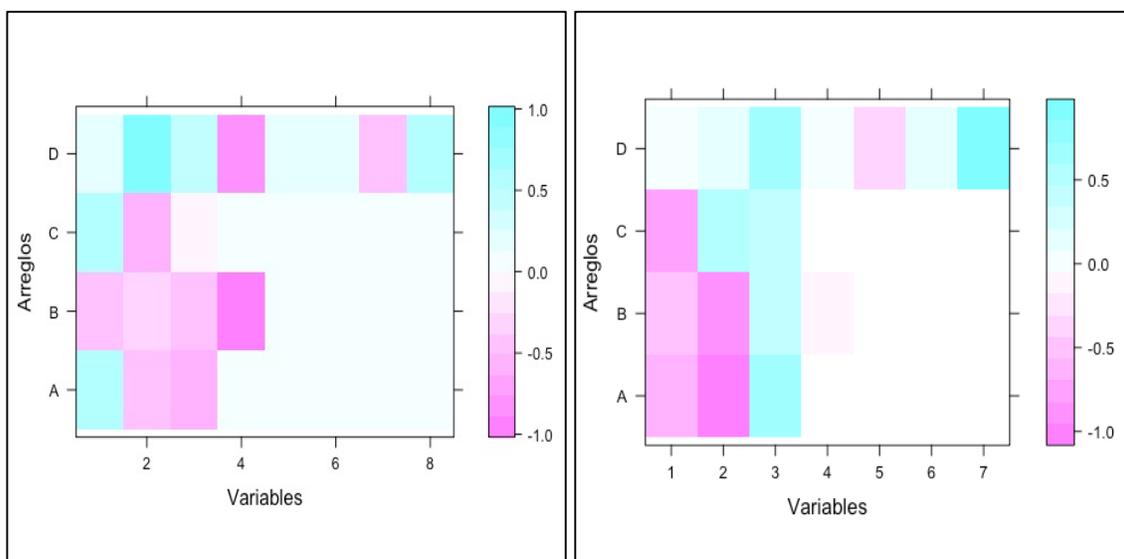
En la Grafica 1, se representan los diferentes valores de error que la red tuvo a lo largo de las iteraciones. Para evitar encontrar mínimos locales se utilizaron diferentes alfas, es decir puntos de inicio de la red. Pero los valores de error fueron consistentes entre la variación dentro de los valores alfa; por lo tanto, se hizo una única representación. La Grafica 1 representa el error general de las redes neuronales, que se tuvo en cuenta durante el entrenamiento de estas mismas. En el eje X, tenemos las iteraciones durante el entrenamiento, en total 60,000 y el error era calculado cada 10,000. El comportamiento que más resalta es el de la función de error del arreglo C, ya que presenta muy poca variación y parece estarse estabilizando. Mientras que el arreglo D presenta la mayor cantidad de variación. Los arreglos A y B se comportan de manera similar, pero el arreglo B tiene valores más altos. El valor mínimo de error, lo tiene el arreglo A, pero los arreglos D y B también se acercan mucho a ese mismo valor.

Los valores de error en los diferentes alfa (.001, .01, .1, 1, 10, 100 y 1000), fueron los mismos. El error se redujo en altas cantidades después de estandarizar los datos, ya que también se compararon los resultados de error al no normalizar los datos y este oscilaba entre 20.1 y 20.9.

En la figura 7, están representados los diferentes pesos sinápticos asignados por la red neuronal artificial según cada arreglo. De nuevo, los valores toman colores mucho más fuertes o sólidos dependiendo de qué tan cerca están a -1 o 1. A diferencia de los errores, los valores tomados por los pesos representan la magnitud de la sinapsis entre neuronas, y el signo, representa la dirección o acción. Al tomar un valor positivo, se está promoviendo la activación de la siguiente neurona; en cambio, si la sinapsis tiene un

peso negativo, se inhibe. Se deben considerar ambos signos, dependiendo de la magnitud del peso. También se debe resaltar que esta es la primera capa de pesos entre la capa de entrada y la capa oculta. Es decir, estos son los pesos asignados a las neuronas de entrada que corresponden a las variables. Los cuadros que tienen un color más claro, o cercano a blanco, representan inactividad. Por lo tanto, esa neurona no se le asignó un alto valor en el peso sináptico, lo que quiere decir que no fue una determinante para la siguiente capa u obtuvo un peso muy bajo. En la Figura 7, hay mayor cantidad de cuadrados con colores rosas, que azules; lo que indica que mayoría de los pesos asignados a las variables fueron negativos. En el arreglo B se asignaron únicamente pesos negativos, mientras que en el resto de los arreglos tienen ambos positivos y negativos.

Figura 7 y 8: Pesos Syn0 y Syn1, respectivamente.



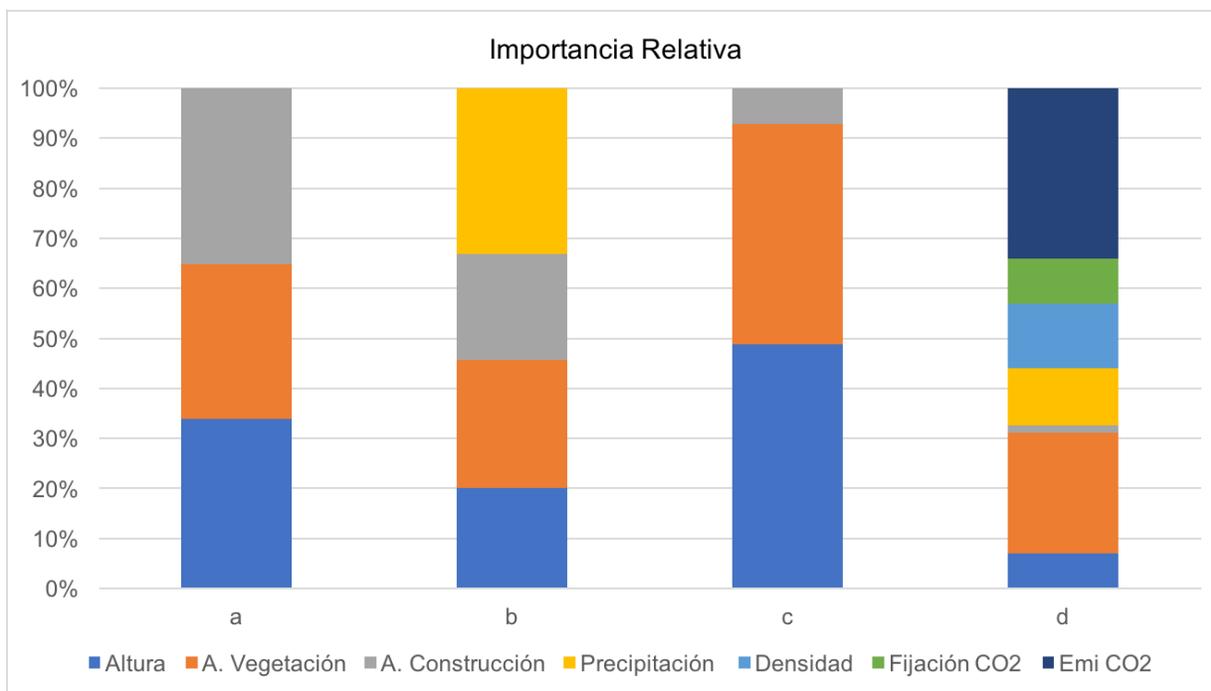
En la Figura 8, se pueden observar la segunda capa de pesos sinápticos entre la capa oculta y la capa de salida. De esta figura es casi imposible poder concluir un resultado, ya que son los pesos asignados a la capa oculta y no representan las variables, de acuerdo con la ecuación en la que se basan las redes neuronales. Los datos para esta gráfica tuvieron que ser de nuevo transformados para poder ser interpretados.

La Tabla 3. Presenta los resultados de método Aproximación de Pesos de Conexiones. Comparando la Tabla 3 y la Figura 8, se puede concluir que, efectivamente, los pesos asignados en la segunda capa de pesos, no corresponden a la importancia asignada por la red. Incluso de ser, sumando ambas matrices presentadas en las figuras 7 y 8, los resultados no representarían los valores asignados a cada variable por arreglo.

Por otra parte, en la Tabla 3 y en la Grafica 2, se puede observar que la distribución de la importancia relativa, es decir la importancia total, en el Arreglo A, fue muy equitativa. Si bien, la variable área construcción superó a las otras variables, fue por muy poco. En el Arreglo B, en cambio la variable con mayor importancia fue precipitación con una diferencia de 6% con el área de vegetación, mientras que a altura y área construcción se

les asigno porcentajes más cercanos. Es interesante que, para el Arreglo C, teniendo las mismas variables que el Arreglo A, se hayan distribuido los pesos de manera diferente. Se puede observar que la variable más importante fue altura, seguida por área de vegetación y por último área de construcción, la que tuvo el peso más bajo. Continuando, en el Arreglo D la variable con mayor importancia por casi 10% fue emisiones CO2, seguidas por área de vegetación y después densidad. Las variables que tuvieron más importancia en los Arreglos A, B y C, no tuvieron mayor importancia en el arreglo D.

Gráfica 2: Importancia Relativa de cada arreglo.



Por otra parte, una variable que a lo largo de los diferentes arreglos tuvo mucha importancia fue área de vegetación. Mientras que la variable de área de construcción fue considerada en una gran proporción únicamente en el Arreglo A, en los demás fue una de las variables con menor importancia relativa. Las variables de fijación de CO2 y densidad no tuvieron mayor impacto en el arreglo D, pero tuvieron un mayor impacto que las otras variables utilizadas en los otros arreglos. Es decir, la suma de la importancia relativa de densidad y fijación de CO2, supera la suma de la importancia de altura, área de construcción y precipitación en el Arreglo D. Al agregar la variable de precipitación en el Arreglo B, la distribución de la importancia entre las otras tres variables varía un poco, pero sigue teniendo casi la misma relación equitativa.

Tabla 3: Importancia Relativa

	A	B	C	D
Altura	33.894880 %	20.1211889%	48.887980 %	7.0165085 %
Área Vegetación	31.0159708%	25.5069713%	43.928448 %	24.0812784%
Área Construcción	35.089148 %	21.2490664%	7.18357192%	1.51736366%
Precipitación	**	33.122773 %	**	11.3139930%
Densidad	**	**	**	12.9643808%
Tráfico	**	**	**	9.02379214%
Emisiones CO2	**	**	**	34.0826833%

Temperatura y predicciones:

Los resultados de la neurona de salida, son los datos que la red neuronal ha predicho con base a los datos esperados, dependiendo de las diferentes variables de cada arreglo. Las Figuras 9 y 10 son Boxplots de los resultados, estos permiten observar las características de la distribución de los datos. Los resultados de cada arreglo, variaron muy poco en grados de temperatura, pero mucho entre arreglos diferentes. De esta manera se puede observar el efecto que tuvo el cambio de variables sobre los resultados, en la figura 10. En la figura 9, se presenta la gran diferencia en la variación de las temperaturas predichas y la temperatura esperada, es decir la original.

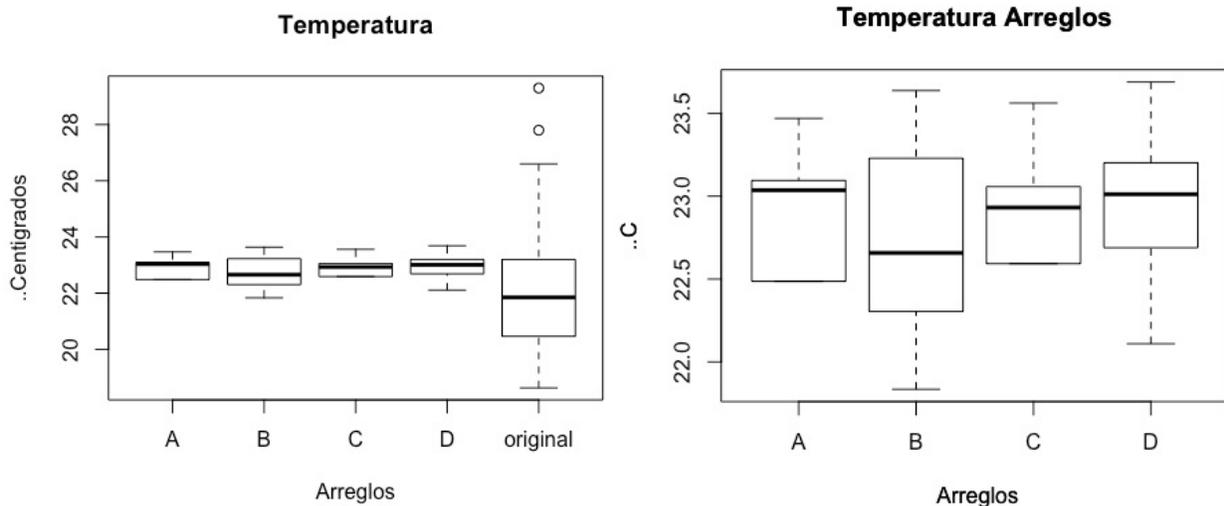


Figura 9 y 10: Boxplots de la distribución de los datos de salida.

La temperatura esperada presenta una gran variación, al contrario; las temperaturas predichas por la red neuronal no. Con respecto a la ubicación del 50% de los datos de los diferentes arreglos en comparación con la temperatura esperada, este no se encuentra en el promedio. En cambio, todas las otras distribuciones están ubicadas en el 3er percentil de la temperatura esperada.

Tabla 4: Observaciones datos

Arreglo A	Arreglo B	Arreglo C	Arreglo D
No presentan variación de mes a mes. Varía de estación a estación Toda su variación está dentro de un centígrado	Varían de mes a mes. Varían de estación a estación. Presenta la mayor variación de temperatura. Menor temperatura promedio y total.	Similar a la distribución del arreglo A, pero temperatura un poco más alta. No hay variación de mes a mes. Si hay variación entre estaciones.	Similar a la distribución del arreglo B con menos variación en mayoría de los datos. Variación entre estaciones y variación de mes a mes.

En la Figura 11, se representan las temperaturas obtenidas a través del tiempo, o las predicciones de cada arreglo. En el eje X, se representan los 12 meses del año. Al graficar los resultados de todas las diferentes redes neuronales se puede observar que lo que menos se vio representado, fue la variación de la temperatura mensual. La temperatura esperada (temperatura máxima 2018) varía de 29 a 18.5°C. Ninguna de las predicciones se comporta igual a la temperatura esperada, si bien el resultado D es el que más se acerca. De igual manera que en la Figura 6, el comportamiento de la temperatura del arreglo C y A es muy similar. A diferencia del comportamiento de B y D, que difieren en la Figura 11.

Tabla 5: Errores de Arreglos A, B ,C y D

Métrica	A	B	C	D
Error Máximo Absoluto	6.09747977	5.665548706	6.521537445	6.298299055
Error Relativo Absoluto	0.152253246	4.284649925	3.703990325	0.359881382
Coefficiente de determinación	0.05020783	0.093243215	0.003690289	0.083329854

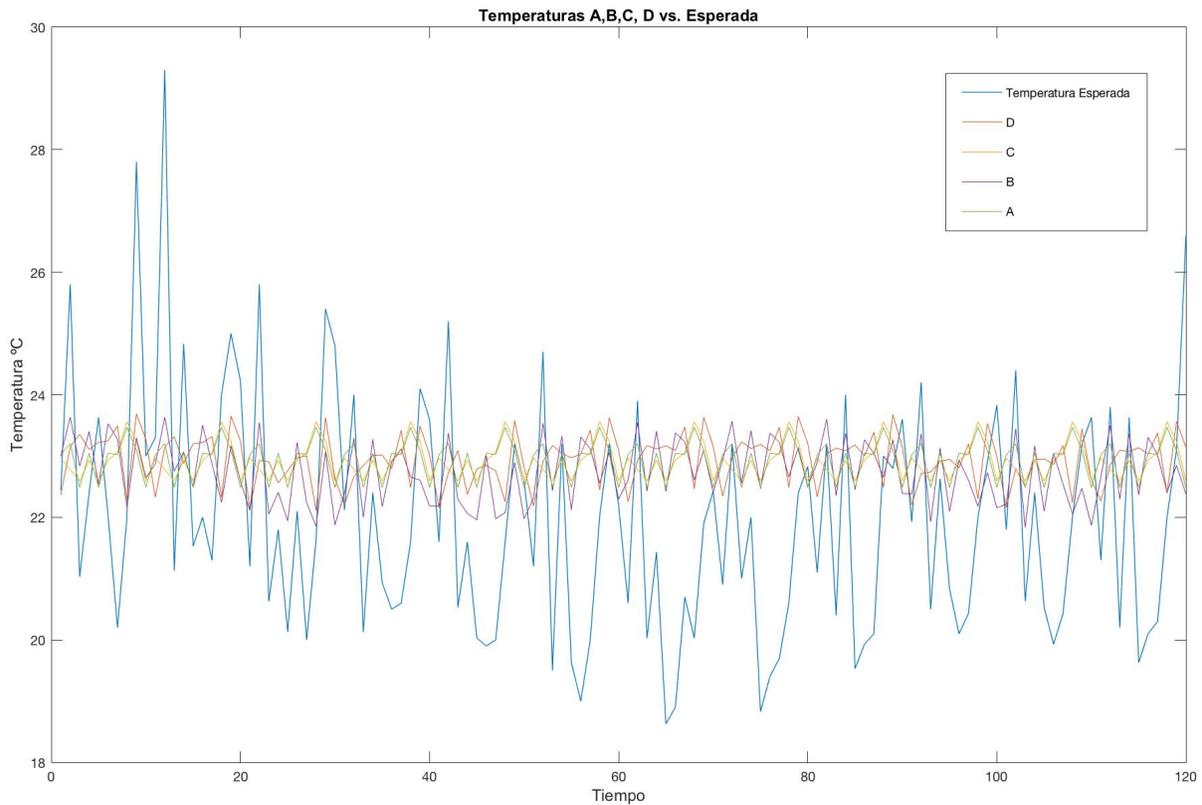


Figura 11: Grafica Temperaturas según arreglo/tiempo.

Proyecciones:

Tabla 6: Errores Proyecciones

Métricas	70%	50%	30%
Error Máximo Absoluto	2.120801003	2.514027042	2.514140592
Error Relativo Absoluto	0.715001894	0.100786889	2.518196074
Coefficiente de determinación	1.061091069/ 0.241640887	0.525378 0.024667265	0.009322805 0.039136985

En la Tabla de Errores de las Proyecciones (Tabla 6), y la Tabla de Errores de las Predicciones (Tabla 5), se pueden observar las diferencias entre las diferentes proyecciones realizadas. El error (máximo) absoluto, representa la diferencia más grande

encontrada entre los valores de las proyecciones de la red, y los valores originales (proyectados). El error relativo absoluto, es una medida utilizada para calcular la precisión, representa el porcentaje de error relativo en todas las medidas. Por último, el coeficiente de determinación (r^2) es una medida que permite comprender la habilidad del modelo para predecir o explicar los resultados. Explica la proporción de varianza en la variable dependiente (temperatura máxima) que es predicha por las variables independientes.

En las predicciones; el menor error lo presentó el Arreglo A. Ya que no tuvo el error máximo absoluto más alto y tuvo el error relativo más bajo. Aún así, este arreglo no tuvo un coeficiente de determinación alto, por lo que no se considera como un buen modelo. El Arreglo B presentó el coeficiente de determinación más alto, y por eso se consideró que era el mejor modelo para utilizar en las proyecciones. El Arreglo C, presentó el menor coeficiente de determinación, por lo tanto fue el peor modelo. Por último, el Arreglo D no se destacó por tener ni los valores más altos y ni más bajos.

A su vez, los errores absolutos de todas las proyecciones tuvieron valores similares; el menor valor lo obtuvo la proyección con el 70% de los datos. El error relativo aumento a medida en la que la cantidad de datos para calibrar disminuía. El coeficiente de determinación tuvo el mismo comportamiento. El valor más bajo en el error relativo y más alto en el coeficiente de determinación los tuvo la proyección con el 70% de los datos. Se puede por lo tanto asumir, que entre menos datos disponibles para la calibración peor será la predicción de la red.

9. Discusión

El análisis de los resultados está estructurado en tres partes diferentes. El primer capítulo corresponde a entender las relaciones establecidas por la red neuronal entre las diferentes variables; teniendo en cuenta la bibliografía revisada, los resultados de los pesos, los errores y las predicciones. Se tiene en cuenta los diferentes arreglos, para comprender como cambian los pesos cuando se agregan variables y aumenta la variación.

La segunda parte corresponde al análisis de las proyecciones realizadas. Se utilizaron datos que han sido adaptados según diferentes informes nacionales y distritales, para probar el trabajo de la red neuronal prediciendo. Se realizaron 3 diferentes escenarios para entrenar la red, utilizando diferentes proporciones de calibración o entrenamiento y validación. En este capítulo, se discute la habilidad que tiene la red neuronal para predecir los valores de la temperatura según escenarios futuros desde el 2020 en adelante. Se tienen en cuenta los diferentes tipos de errores para cada tipo de proporción, para evaluar que tan buena fue la ejecución de la red neuronal.

Por último, el tercer capítulo aborda el tema general de las redes neuronales como una herramienta para el análisis y predicción de los sistemas urbano-naturales. Teniendo en cuenta las limitaciones encontradas durante la realización de los ejercicios previos y otros estudios revisados. Entra a consideración la utilidad de las predicciones y se dan diferentes recomendaciones para trabajos en redes neuronales en el futuro.

9.1 Pesos sinápticos

Considerando lo planteado por Olden et al. (2004), los pesos sinápticos deben ser reconocidos por su magnitud y dirección. Otros autores consideran que además de predecir, las redes neuronales identifican y aprenden sobre patrones que correlacionan los datos de entrada y salida (Lek and Gue 1999). Los pesos sinápticos dentro de una red neuronal artificial representan la no linealidad del procesamiento. Ya que, como se puede ver en las Figuras 7 y 8, la magnitud y dirección de los pesos puede cambiar de una capa a otra. Puesto que, en mayoría de los estudios relacionados con Ecología, en los que utilizan redes neuronales; se recomienda tener una única variable en el output. Se sugiere que las redes neuronales con esta arquitectura (entrada-oculta-salida) son capaces de aproximar cualquier función (Hornik et al. 1989). Las variables del input, con pesos asignados más grandes representan más intensidad en su señal transferida, y por lo tanto son más importantes en el proceso de predicción comparado con las variables con pesos más pequeños. Los pesos negativos en una conexión representan efectos inhibidores en las neuronas, que reducen la intensidad de la señal; y si, el valor asignado es positivo, el patrón de conectividad es excita, y es más probable que la siguiente neurona se active (Olden and Jackson 2018).

En la Figura 7, se pueden observar los diferentes pesos asignados a las variables en la primera capa de pesos sinápticos (Syn0). Para el Arreglo A, la red le asignó la mayor magnitud a la altura, después construcción y por último vegetación. En este caso, la variable de altura sería la más importante. Según la red, incide más sobre la temperatura máxima. En cambio, para las variables de construcción y vegetación, tienen una menor magnitud y su valor es negativo. Por lo cual, sus valores no tuvieron tanto poder explicativo para la primera capa.

Los resultados del Arreglo A para la primera capa de pesos sinápticos indican que la variable con mayor importancia inicial es la altura de los predios. Teniendo en cuenta que la altura promedio de todos los predios en las localidades estudiadas, tuvieron un promedio de 2.4 pisos (Catastro 2018). Dado que se ha demostrado que las áreas urbanas con edificios con menos altura tienden a tener ciclos diurnos más largos. Entre más bajos sean los edificios y homogéneos; la temperatura superficial aumenta durante el día. Entre menor altura también menos sombra se crea, haciendo que las temperaturas durante la noche disminuyan por menos radiación de honda larga atrapada en los cañones urbanos (calles). En las simulaciones de altura realizadas por Loughner et al. (2012), se observó que disminuir el tamaño de los edificios, en una misma área, causa un aumento de temperatura de hasta 1.5°C, y baja la temperatura nocturna .6°C (Loughner et al. 2012). Es decir, si la morfología urbana, tiene como resultado bloques de edificios bajos con la misma altura; podría tener un aumento sobre la temperatura.

Teniendo en cuenta que en las Figuras 7 y 8, se observa que los pesos asignados cambian de dirección de capa a capa. De esto se puede asumir que la relación entre la altura y la temperatura máxima no es lineal, pero es representativa. Se observa que después del análisis de las dos capas de pesos, la variable con mayor importancia relativa es área construida. Esto se puede explicar por los principios del albedo y la impermeabilidad. Las ciudades altamente urbanizadas, usualmente tienen albedos entre

.15 a .30, dependiendo de los materiales utilizados y la heterogeneidad del paisaje (Taha 1997). Sus superficies solamente están reflejando entre el 15 y 30% de las ondas cortas que reciben, almacenando el resto y liberándolo después; creando islas de calor. Desafortunadamente no existen datos para el albedo de Bogotá D.C, pero se conoce que existe una relación entre el área urbana está relacionada y la temperatura máxima. Por otra parte, en la Gráfica 2 y en la Tabla 3, se puede observar que la variable altura tuvo una importancia relativa del 33.89%, y que también es muy cercana a las otras importancias. Es decir, la diferencia en la importancia relativa fue muy baja; lo que indica que la red neuronal tuvo en cuenta a las tres variables para representar la predicción. Los resultados del Arreglo A, en general, fueron una reafirmación de las variables utilizadas en mayoría de los estudios relacionados con el fenómeno isla de calor.

A su vez, en el arreglo B los pesos asignados en la primera capa de pesos sinápticos muestran que la variable con mayor magnitud es precipitación. Tiene un valor negativo, por lo tanto, inhibe a las siguientes neuronas para que no se activen. Después de considerar los pesos asignados a la capa oculta, la variable de precipitación es sin duda, la variable con mayor importancia en este arreglo. Sin embargo, como se puede observar en la Tabla 3, no tiene un valor negativo total, es decir no inhibe la activación de las siguientes neuronas. Se afirma que hay una relación fuerte entre la temperatura máxima y la precipitación, pues su importancia relativa supera la de las demás variables. Se ha demostrado que existe una relación directa entre la precipitación y el fenómeno isla de calor (Dixon and Mote 2003). Ya que, debido a la inestabilidad atmosférica creadas por las altas temperaturas, se puede promover periodos de precipitación (Blake et al. 2011). Pero este fenómeno usualmente ocurre en una escala de horas, y este estudio trabajó sobre una escala mensual. Por lo tanto, se debe considerar que la red neuronal, predice la temperatura máxima, con base a la precipitación a una escala mensual, que no permite concluir que la relación entre esas dos variables se da debido al fenómeno isla de calor.

De este arreglo si se puede deducir que se encontró una relación más fuerte entre la temperatura máxima y la precipitación, que entre la temperatura máxima y las variables área de vegetación, área de construcciones y altura. Esto no es excluyente, pues no se está afirmando una relación de causalidad. Si bien se reafirma que existe una fuerte relación entre temperatura máxima y precipitación, no se excluyen las demás relaciones.

A diferencia de los otros arreglos, el Arreglo C intentó predecir también la precipitación, pero sus resultados no fueron incluidos. Este arreglo tuvo como objetivo, observar si existía una diferencia en los pesos asignados a las variables al tener dos variables de salida. Efectivamente, los resultados difieren significativamente de los resultados obtenidos para el Arreglo A. Además, en el Arreglo C, no se tiene certeza si se encontró un error mínimo local, o total en la Grafica 1. Mientras que el error de sus predicciones no fue el más alto comparado con los otros arreglos en la Figura 6, su coeficiente de determinación fue el más bajo de todos. Observando la Tabla 3, se concluye que este arreglo le dio mayor importancia a la variable de altura y a la variable de vegetación. En cambio, la variable de área construida, que fue la más importante del Arreglo A, tuvo la importancia relativa más baja; de hecho, casi la más baja de todas las importancias relativas.

Los resultados del Arreglo C son muy inciertos. Igual que los otros arreglos, este presenta un error alto, y un coeficiente de determinación extremadamente bajo. Además, desafía las recomendaciones de únicamente tener una variable en la capa de salida. Por lo que se podría suponer que deberían ser considerados los resultados del Arreglo A, en vez del Arreglo C. Es interesante, por otra parte, que, en el Arreglo D, con muchas otras variables; también tuvo como resultado una importancia relativa mínima para la variable área construida. De nuevo, el coeficiente de determinación del Arreglo D, es bajo, pero un poco más alto que el del Arreglo A.

El Arreglo D, es el que más variación presenta y también en el que se incluyen más variables urbanas como densidad, tráfico y emisiones de CO₂. Los pesos sinápticos de la primera capa atribuyen mayoría de su peso a la vegetación, a las emisiones de CO₂ y a la precipitación. Por su lado, los resultados de la importancia relativa, le atribuyen el mayor porcentaje a las emisiones de CO₂, con una diferencia casi de 10% entre esta variable y la siguiente, área de vegetación. Después densidad y precipitación, con poca diferencia entre ellas. Los resultados de la primera capa de pesos y la importancia relativa ambos incluyeron las emisiones de CO₂. Ninguna de las 3 variables de los arreglos A y C tienen valores de importancia relativa altas. Finalmente, se debe reiterar que en general todos los arreglos tuvieron un coeficiente de determinación extremadamente bajo. Esto pone en duda los resultados.

Las variables que presentaron mayor importancia relativa y también tuvieron pesos con gran magnitud asignados en la primera capa fueron: área de construcción, área de vegetación, precipitación y emisiones de CO₂. Las primeras dos, constantemente relacionadas con el fenómeno isla de calor (Vuckovic et al. 2017)(Blake et al. 2011). La precipitación se relaciona con el fenómeno isla de calor a través de una relación de causalidad (Blake et al. 2011) . Mientras que, a las emisiones de CO₂ , catalogadas como antrópicas; les atribuyen algo de influencia, pero la variable se excluye en múltiples estudios(Chapman et al. 2017a) , y usualmente están asociadas con el tráfico (Fujii et al. 2017). Paradójicamente, en los estudios centrados en las emisiones, reiteran su importancia y más allá relacionan las emisiones de CO₂ con el agravamiento de los problemas de salud causados por la isla de calor (Blake et al. 2011, Chapman et al. 2017a).

En contraste con lo anterior, se prioriza más la variable de emisiones de CO₂, en las estrategias para mitigar los impactos del fenómeno isla de calor (Gago et al. 2013). Se considera que las emisiones de CO₂ están relacionadas directamente con el uso del suelo, resaltando las emisiones de las industrias, los contaminantes y el tráfico (Breuste 2012, Mathew et al. 2017). Las propuestas de mitigación están ligadas con la planeación urbana, de los diferentes usos de suelos, sugiriendo e incentivando los arreglos heterogéneos (Chapman et al. 2017a). La variable de emisiones de CO₂ fue la única variable que no estaba constantemente incluida en la revisión bibliográfica y que tuvo un resultado en la importancia relativa muy alta. Por lo tanto, se puede sugerir, que es necesario abordar las emisiones desde diferentes investigaciones para evaluar su relación con el fenómeno isla de calor.

A simple vista no es posible evaluar los pesos de la segunda capa, ya que las neuronas

en la capa oculta no representan las variables de la capa inicial. Las neuronas en la capa oculta son los resultados de la sumatoria entre los valores, los pesos y el voltaje de polarización después de haber pasado por la función de activación, es decir, una mezcla de todas las variables anteriores. Por lo que no se puede interpretar los pesos literalmente. Este es una de las desventajas de las redes neuronales; si bien, se considera que tienen muy buenas capacidades para predecir, las relaciones asignadas entre variables dependientes e independientes no son explícitas (Lek and Gue 1999). Esta es la principal crítica de las redes neuronales artificiales, ya que su razonamiento detrás de las predicciones funciona como una 'caja negra'.

Una desventaja de las redes neuronales es la falta de consenso en cómo deberían ser interpretados los pesos sinápticos. Si bien existen autores que consideran que estos aportan resultados claros e interpretables (Olden et al. 2004, Quetglas et al. 2006, Olden and Jackson 2018) , existen otros que consideran que los pesos no presentan información y que en incluso deben ser utilizados en otras pruebas o incluso, más allá, transformados (Lek and Gue 1999). Uno de los motivos por el cuál las redes neuronales no han tenido un boom en la ecología, es por la falta de métodos que sirven para cuantificar la contribución de las variables independientes dentro de las redes (Olden and Jackson 2018). Ya que, dentro de los intereses de la ecología esta en reconocer y estudiar relaciones. Existen métodos exhaustivos como algoritmos de crecimiento y poda (Bishop, 1995), Derivadas parciales, pruebas t asintóticas, entre otros. Estos métodos si bien, son más simples, y ayudan a determinar la influencia de cada variable independiente. Aún así, las interacciones entre variables son más difíciles de interpretar; pues se debe tener en cuenta la magnitud y la dirección de cada axón individual que conecta las pesas, y debe ser analizado directamente (Olden and Jackson 2018). A su vez los dos métodos utilizados en este estudio para la transformación de los pesos, con el fin de evaluar la contribución de las variables independientes en la red. Son unos de los muchos métodos disponibles para la interpretación (Olden et al. 2004). Existen otros métodos recomendados para analizar los pesos sinápticos como los mapas tipo Kohonen, o mapas que se auto-organizan. Estos aproximan la función de densidad probable de los datos de entrada, en una representación más comprensible (Quetglas et al. 2006).

Por último, se considera que los resultados de este trabajo son un aporte, ya que traen a la luz las diferentes variables que se deberían tener en cuenta frente al manejo del fenómeno isla de calor en Bogotá D.C. En el 2014, la OECD, planteo que las ciudades tienen un rol clave en el manejo del cambio climático, a través de su diseño y planeación. Por otra parte, durante el 2015 se firmó el Acuerdo de Paris (UNFCC), en el cuál se plantea disminuir las emisiones totales globales. El pasado 29 y 30 de octubre (2018), se reunieron los alcaldes del mundo en Buenos Aires, para discutir la implementación de lo pactado en París a nivel local y los retos para las ciudades; bajo el marco de Urban20. Se deben considerar las emisiones liberadas por cada tipo de cobertura en Bogotá, si bien según el último censo urbano, todas las localidades incluidas en este estudio eran predominantemente de uso residencial; sus emisiones están relacionadas con la temperatura máxima. Es aceptado, que el crecimiento urbano en las siguientes décadas aumentará el fenómeno isla de calor, teniendo en cuenta también los impactos del cambio climático. La habilidad de adaptarse a estos impactos esta obstaculizada por la

falta de información en las regiones más vulnerables, entre ellas Sudamérica; también por la falta de inclusión de variables como las emisiones antrópicas, entre otras (Chapman et al. 2017a). El crecimiento urbano conlleva a la construcción de nueva infraestructura, que incide sobre las variables resaltadas en este estudio. Es crucial tener en cuenta los efectos de la urbanización sobre el clima para la planeación urbana si se plantea una mitigación de los impactos del fenómeno isla de calor, y del cambio climático en Bogotá D.C.

9.2 Proyecciones

Los resultados de las predicciones de los diferentes arreglos tuvieron muy poca variación en comparación con los datos originales. Dicho lo anterior, los datos no representan la variación mensual. Los resultados de las predicciones de los arreglos fueron suavizados por la red neuronal, es decir que consideró los extremos de temperatura máxima como valores atípicos y ruido. En la Figura 9 y 10, se puede observar que: en comparación con los datos originales, los resultados de los arreglos se agruparon alrededor del tercer percentil y su variación no supera 2°C. Esto puede haber ocurrido debido a que únicamente se incluyeron los datos meteorológicos para el 2017, considerando que los únicos datos urbanos disponibles eran del 2017. No obstante, también puede haber sido resultado de la manera en la que se organizaron los datos. En las fases preliminares, cuando se inició a evaluar el desempeño de la red neuronal, se concluyó que organizar los datos por estaciones no representaban suficiente variación. La temperatura variaba considerablemente entre estaciones, pero las otras variables tuvieron un comportamiento totalmente estático. Variables como densidad, área construida y vegetación, entre otras; no cambiarían a lo largo de los meses si se organizaban los datos con base a las estaciones.

Al organizar los diferentes arreglos, no solamente se tuvo en cuenta la revisión bibliográfica; pero también se buscó aumentar la variación dentro de la estructura de estos mismos. Conforme a esto, se buscaron variables adicionales que siguieran en el marco bibliográfico revisado, pero que tuvieran diferentes representaciones. Sirva de ejemplo las variables de densidad, para también representar el área construida. Ahora bien, desconociendo las relaciones exactas entre las variables independientes y la temperatura máxima, se consideró que, al tener mejor representación del sistema, se obtendrían mejores resultados. El arreglo D, presenta el error más alto en sus predicciones, un coeficiente de determinación muy bajo y también representa la mayor cantidad de variación. Lo que demuestra, que no necesariamente teniendo más variables, se obtendrá un mejor resultado. No obstante, el arreglo D permitió observar si otras variables fueron consideradas más importantes que las que originalmente se obtuvieron de la bibliografía.

Curiosamente, los datos predichos por la red, tuvieron comportamientos extraños, o no esperados. En los arreglos A y B no hubo variación de mes a mes; estos dos arreglos no incluyeron precipitación como variable independiente, y tuvieron como resultado un solo valor por estación. Estos fueron parte de los resultados pre-eliminares, que dieron indicios que los datos necesitaban más variación para tener mejores resultados. Por otra parte, el arreglo B, presentó más variación dentro de sus datos, que los demás arreglos,

sin presentar todas las variables disponibles. En sus predicciones tuvo un error alto, más alto que los arreglos A y C; claramente debido a que si hubo una variación en sus resultados. Presentó el coeficiente de determinación más alto y el error máximo absoluto más bajo.

Las predicciones de los arreglos, como se mencionó anteriormente, no representan el comportamiento de la temperatura máxima, durante el 2017. Si bien, en la figura 11 se puede observar que ninguna de las predicciones de los arreglos, iguala o se acerca a la temperatura original. La predicción de los arreglos A y C son extremadamente similares en algunos meses. Difieren totalmente de las predicciones del Arreglo B y D. Por otra parte, el arreglo B y D no tienen un comportamiento similar. Puesto que los arreglos A y C comparten las mismas variables de entrada, sin embargo, el arreglo C también tiene la variable de precipitación de salida y sus resultados difirieron considerablemente. Lo que puede indicar que tener más de una variable de salida puede afectar el desempeño de la red.

El Arreglo B, se comporta de manera similar a la temperatura máxima durante los primeros meses del año, pero según el coeficiente de determinación no es una buena predicción ($r^2 = .093243$); aunque es el valor más alto entre los cuatro arreglos. El objetivo de observar las predicciones realizadas por los diferentes arreglos, era encontrar el set de variables que más representaran o se ajustaran a la variación de la temperatura máxima. Por esto mismo, se escogió el arreglo B para realizar las proyecciones.

Luego, para las proyecciones como se mencionó anteriormente en la metodología, se utilizaron 3 diferentes combinaciones de calibración y validación. El mejor resultado lo tuvo la proyección en la que se utilizaron el 70% de los datos para entrenar. No solamente tiene el coeficiente de determinación más alto, incluso más alto que el del arreglo B, pero también tiene el error máximo absoluto y el error relativo absoluto, más bajo. A pesar de diferir en sus coeficientes de determinación; el arreglo B y la proyección con el 70% de los datos tienen casi los mismos pesos asignados a las variables. En las siguientes tablas se pueden observar los pesos de la primera y segunda capa.

Tabla 7: Pesos sinápticos de la primera capa

Red Neuronal	Peso V1	Peso V2	Peso V3	Peso V4
Proyección 70%	-0.39240968	-0.37160061	-0.43337409	-0.89261574
Arreglo B	-0.39249075	-0.37131815	-0.43347073	-0.89246288
Diferencia	8.107E-05	-0.00028246	9.664E-05	-0.00015286

Tabla 8: Pesos sinápticos de la segunda capa.

Red Neuronal	Peso V1	Peso V2	Peso V3	Peso V4
Proyección 70%	-0.45235029	-0.87076964	0.4012383	-0.11259442
Arreglo B	-0.45353559	-0.87173484	0.39967302	-0.11395216
Diferencia	0.0011853	0.0009652	0.00156528	0.00135774

Si bien, en la primera capa de pesos sinápticos, la diferencia es muy pequeña, en la segunda capa, la diferencia aumenta. Esta leve variación en los pesos, debido a la cantidad de datos en las capas de entrada es contradictoria con los principios de la red neuronal. Que si bien tienen un desempeño excelente con poca cantidad de datos, deberían mejorar sus resultados cuando la cantidad de datos aumenta (Maier and Dandy 2001). Esto incluso, a pesar de que los datos para las proyecciones no fueron seleccionados al azar. Se escogieron los primeros 84 datos (70%), ignorando el tiempo, que solo representarían los primeros 8 meses y medio. Los resultados de la red neuronal presentados en la Tabla 6, se hicieron con los datos de validación (30%), restantes. Estos representaban los últimos 3 meses y medio. En la Figura 11, se puede observar que el comportamiento de la temperatura máxima, varía considerablemente a través del tiempo. Durante los primeros meses presenta extremos más altos, que durante los últimos meses. A pesar de esto, el coeficiente de determinación fue más alto. Cabe rescatar que el valor del coeficiente de determinación para la proyección con el 70% de los datos, sigue siendo extremadamente bajo.

Las redes neuronales mejoran su desempeño, dependiendo de su arquitectura, repeticiones, y datos (Maier and Dandy 2001, Quetglas et al. 2006, Zhang 2010). Por otra parte, para la predicción acertadas en cortos periodos de tiempo, la red neuronal requiere muchos datos y toma mucho más esfuerzo para calcular (Liu et al. 2010). Una de las falencias, es que estos parámetros no están establecidos, es decir no existe una guía o supuestos para construir la red; usualmente es un proceso de prueba y error (Maier and Dandy 2001, Quetglas et al. 2006). Es posible que, durante este ejercicio, no se haya encontrado la arquitectura óptima o, no se hayan utilizado la suficiente cantidad de datos. En las fases iniciales de la construcción de la red, se logró disminuir el error total, de un 20 a un .9, al estandarizar los datos, a pesar de que algunos autores reiteraban que no es necesario (Shanker et al. 1996, Maier and Dandy 2001); otros reiteraban su importancia (Olden and Jackson 2018). Se aumentó la variación de los datos para representar mejor el sistema, pero tuvo resultados opuestos a los esperados, y se suavizaron los datos. Se logró disminuir el error, pero este continuó siendo alto. Uno de los varios atractivos de las redes neuronales es la habilidad de ser muy flexibles con los datos y presentar un excelente desempeño, que en varias ocasiones han sido comparados con los modelos estadísticos tradicionales, y tienen un mejor desempeño. Lo anterior no se vio reflejado en el estudio, los valores para los coeficientes de determinación fueron muy bajos, y las predicciones no fueron lo esperado.

9.3 Redes Neuronales como herramienta

Es importante aclarar, que lo planteado a continuación parte únicamente de la realización de este estudio, no había conocimiento previo y no se tienen otras aproximaciones a las redes neuronales. Por otra parte, resaltar la naturaleza del estudio y sus datos; teniendo en cuenta que se enfoca en un ecosistema urbano y la naturaleza de sus datos no son netamente naturales.

Para este estudio se utilizó la herramienta de Redes Neuronales Artificiales por sus amplios beneficios en manejo de datos, por la precisa habilidad para predecir y grande potencial para su utilización en el análisis de ecosistemas (Lek and Gue 1999, Quetglas et al. 2006, Liu et al. 2010).

Muchos de las limitaciones presentadas a la hora de analizar ecosistemas totalmente naturales, o en este caso, intensamente habitados por los humanos es comprender las relaciones que mayoría de las veces no son lineares, no son sencillas, y están bajo constante cambio y presión(Quetglas et al. 2006, Alberti 2008). Los métodos tradicionales, usualmente estadísticos, tienden a ser el único método de análisis en cuanto a los sistemas naturales. Estos no siempre representan adecuadamente las relaciones complejas que se intentan describir. Los métodos estadísticos no solamente requieren de muchos supuestos que se deben cumplir antes de iniciar los pruebas, pero también no siempre permiten evaluar el comportamiento real de los datos.

Los ecosistemas funcionan como redes complejas, son sistemas no lineares, establecidos por muchos componentes bióticos y abióticos que están interconectados, no siempre de manera obvia. Muchas de las interacciones dentro de un ecosistema no son claras, no están distribuidas aleatoriamente, se adaptan y están constantemente en cambio, como respuesta al ambiente (Quetglas et al. 2006). En el caso de los sistemas urbanos, estos supuestos son ciertos, ya que, también se incluye la complejidad y diversidad de las culturas humanas, valores, percepciones y evolución a través del tiempo. Si bien los ecosistemas urbanos difieren de los naturales en el clima, suelo, hidrología, composición de especies, dinámicas de población, flujos de materia y energía; las relaciones entre sus componentes no son iguales, pero pueden ser semejantes. Desde una perspectiva de la ecología de las ciudades; se entiende que los humanos creamos patrones ecológicos, procesos, disturbios diferentes a los presentes en un sistema natural. Esto agrega incluso más complejidad e incertidumbre a los sistemas, ya que para diferentes autores, hace que sean más complejos de analizar y predecir (Alberti 2008). Así mismo, las herramientas utilizadas en la Ecología aplicadas a los sistemas urbanos que intentan simultáneamente representar procesos humanos y ecológicos, se ven simplificando los procesos humanos. En los ecosistemas urbanos, las dinámicas humanas son las fuerzas dominantes a través de las estructuras demográficas, socio-económicas y políticas. (Alberti, 2008).

Según Alberti (2008), los ecosistemas urbanos son: híbridos, sistemas jerárquicos en los cuales emergen múltiples dinámicas y agentes que interactúan entre sí, y con el ambiente. Son sistemas complejos adaptativos, que son abiertos, no lineares y altamente impredecibles. Los disturbios son una característica inherente a estos, y el cambio tiene

muchas causas, con diferentes motivos, altamente dependientes en contextos históricos, u otros (Alberti 2008). Las redes neuronales artificiales, por lo tanto, se prestan como una opción para el análisis de estos sistemas ya que modelos que recogen información del ambiente y proponen una respuesta después de haber sido entrenados por diferentes algoritmos. Más aún, las características de los datos urbanos son diferentes a los de otras ciencias, tienden a ser voluminosos, no lineales, complejos, con mucho ruido, redundancia, relaciones internas y valores atípicos (Park et al. 2003^a)(Quetglas et al. 2006).

Según Quetglas et al. (2006), hay varios estudios que comparan las redes neuronales artificiales con modelos estadísticos. Alterando algunos parámetros de las estructuras de las redes, como la función de transferencia (sumatoria), o cantidad de nodos ocultos. Comparando las redes de alimentación positiva, con modelos lineales generalizados (GML) y el entrenamiento o fases de aprendizajes a fases de estimación en modelos estadísticos convencionales. En los resultados evaluados en los diferentes resúmenes, se concluyó que las redes neuronales tienen mejores resultados o un mejor desempeño comparándolas con pruebas estadísticas. En términos de predicciones y representación de las relaciones; siempre y cuando se utilicen estrategias óptimas para el entrenamiento, la arquitectura y no haya limitación de datos. (Quetglas et al. 2006).

Se considera que, durante la construcción y el entrenamiento de la red neuronal utilizada para este estudio, algunos de los supuestos mencionados previamente se cumplieron; mientras otros no. Los beneficios de trabajar con redes neuronales fueron: (1) no hubo necesidad de transformación exhaustiva de los datos, previos al análisis. Los datos fueron estandarizados, ya que se demostró que la red mejoraba su desempeño al hacerlo. No existían diferentes supuestos que deben ser cumplidos para poder aplicar algún tipo de prueba o realizar un análisis. (2) Teniendo en cuenta la magnitud de iteraciones de las ecuaciones realizadas y el tamaño de los datos de entrada y salida; la red neuronal trabaja extremadamente rápido. Por otra parte, las redes neuronales permiten (3) tener una perspectiva diferente, sobre un problema que ha sido abordado reiteradamente, de la misma manera. Sin desprestigiar los métodos estadísticos tradicionales; el enfoque de las redes neuronales permite reiterar los resultados ya presentados, o darle luz a aspectos que de pronto han sido obviados anteriormente. No funciona de manera lineal y presenta datos descriptivos diferentes. Las redes neuronales también presentan flexibilidad; (4) no solo en los datos, pero también en (5) los métodos internos. Partiendo de la arquitectura de las redes neuronales, que puede ser un arma de doble filo; existen diversas opciones para la construcción de una red neuronal. La cantidad de capas ocultas y la cantidad de neuronas; son alternativas disponibles para optimizar el desempeño de las redes neuronales. En este estudio, se considera que su aprovechamiento de la arquitectura de las redes neuronales, no llegó a su máximo potencial. (6) La construcción y las posibilidades de ecuaciones para cada fase de la red neuronal, también presentan diferentes opciones para ajustar de mejor manera la red al sistema que se está estudiando. Existen diferentes ecuaciones de activación, maneras de calcular el voltaje de polarización; que presentan aún más posibilidades.

Si bien las redes neuronales tienen muchos beneficios, durante el desarrollo de este estudio también se encontraron algunas desventajas. La desventaja principal de las

redes neuronales, mencionada en mayoría de los artículos revisados, es la falta de revelación, ampliamente conocida como la 'caja negra'. Si bien las redes neuronales y el conocimiento profundo; es reconocido por sus excelentes resultados para predecir, su mayor falla es la falta de explicación. Los resultados son casi inmediatos, pero para poder analizar los pesos sinápticos o lo que ocurre en las capas ocultas; existen muchos métodos que transforman exhaustivamente los resultados y hasta, en algunos casos, implican repetir el procesamiento de la red neuronal. Olden and Jackson (2018) demuestran que las redes neuronales no trabajan como una caja negra, ya que existen métodos para interpretar los resultados y de estos sacar conclusiones. La 'caja negra' es interpretable, pero requiere de más tiempo, esfuerzo y análisis; después de escoger un método. Como se había mencionado previamente, en el caso de los ecólogos, es vital conocer las relaciones entre las diferentes variables, y no solamente predecir un resultado.

En vista de lo anterior, otra de las desventajas de las redes neuronales son la cantidad de opciones; también considerada como una ventaja. La cantidad de opciones disponibles hace que la construcción, y optimización de la red neuronal sea un proceso extremadamente largo. Muchos autores recomiendan tener mucha experiencia para trabajar con redes neuronales, especialmente porque es complicado aprender cómo mejorar la red para obtener mejores resultados. Desde la arquitectura, la cantidad de capas y neuronas, hasta las ecuaciones y las diferentes maneras en las que se pueden organizar los datos. Si bien, en este estudio no se comparan las redes neuronales con las pruebas y modelos de estadística normales; es válido resaltar que estos son mucho más estáticos. Los modelos tradicionales estadísticos tienen supuestos, dependiendo de la distribución de los datos, tamaño, entre otras cosas; se define la prueba más apta y se aplica. En contraste, este principio no necesariamente se aplica a las redes neuronales. En las redes neuronales son demasiado maleables, pero tienden a tener excelentes resultados.

10. Conclusiones

Para concluir, las redes neuronales son una manera diferente de abordar los problemas y sistemas ecológicos. La construcción y el diseño de una red, no solo permite comprender como funcionan las redes neuronales, pero también aborda la problemática del Fenómeno Isla de Calor desde otra perspectiva.

En el análisis de las diferentes variables relacionadas con el Fenómeno Isla de Calor se encontró que las variables más importantes, según la red neuronal, fueron: la precipitación, altura, área de vegetación y emisiones de CO₂. Si hubo diferencias significativas entre los diferentes arreglos. Las variables que inicialmente se consideraron importantes en los primeros arreglos, no lo fueron en los arreglos que representaban mayor variación. También se encontró que una de las variables menos estudiada, emisiones de CO₂, fue una de las variables más importantes. Teniendo en cuenta que, la variable del tráfico, no fue importante. Es necesario considerar el tipo de emisiones de CO₂, diferentes al tráfico, presentes en Bogotá D.C y su incidencia sobre el Fenómeno Isla de Calor.

Las proyecciones y predicciones realizadas por la red neuronal fueron suavizadas. No se reflejó en estas, la variación climática anual, en cambio, se ajustaron al promedio. La mejor predicción no la tuvo el arreglo con mayor variación o mejor representado. Al contrario, el mejor coeficiente de determinación lo obtuvo el Arreglo B, incluyendo las variables de morfología urbana y precipitación. Por otro lado, la proyección del 70% de datos utilizados para la calibración tuvo el coeficiente de determinación más alto en todo el estudio. Los pesos sinápticos de la primera capa utilizados en esta proyección fueron muy similares a los pesos sinápticos de la primera capa, del Arreglo B. La diferencia ocurrió en la segunda capa de pesos sinápticos. La red neuronal también, tuvo mejores resultados con menos cantidad de datos (70%). Para concluir, la red neuronal construida para este estudio no tuvo predicciones acertadas, y sus coeficientes de determinación en general fueron muy bajos.

Las redes neuronales presentan un sin número de opciones, por lo tanto, son útiles para describir sistemas ecológicos. Su manera de procesar no es lineal, y son capaces de establecer relaciones no lineales entre variables, aun así estas no sean explícitas. Considerando lo anterior, no existe una única metodología para asegurar su buen desempeño. Mayoría de los autores revisados, consideran que es un proceso de prueba y error, y que entre más experiencia se tenga en redes neuronales, mejor. Este estudio fue un primer acercamiento a las redes neuronales, y si bien, se exploraron diferentes variaciones de los datos y variables, no se exploró a profundidad la arquitectura de la red. Para este estudio, el desempeño de la red neuronal fue sub-óptimo; esto no significa que en general las redes neurales no sean una herramienta apropiada para la ecología. Sin embargo, para futuras investigaciones, el desempeño de este modelo debe mejorar considerablemente.

Este estudio tuvo varias limitaciones a lo largo de su desarrollo. Es importante recalcar que la escala usualmente utilizada para observar y evaluar el fenómeno isla de calor, es horaria y no mensual. Para la construcción de los data sets utilizados en la red neuronal, tener una escala tan amplia significaba obtener datos urbanos que no estaban disponibles y tamaños de matrices extremadamente grandes. Por otra parte, la red pudo haber representado mejor el fenómeno isla de calor en Bogotá D.C, si se hubieran incluido datos históricos. Es decir, datos urbanos y meteorológicos de por lo menos 10 años atrás; con el fin de observar cambios en las variables. Todos los arreglos tuvieron un coeficiente de determinación bajo. El coeficiente de determinación pudo haber aumentado si se hubieran explorado diferentes arquitecturas neuronales, agregando capas y neuronas ocultas. Ya que no hay un consenso en cómo se debería construir una red neuronal óptima este es un proceso de prueba y error. Por último, la mayor limitante durante el estudio fue la interpretación de la red neuronal. Si bien, los datos fueron transformados, e interpretados. Estos requieren aún más transformación para poder observar relaciones. Lo que reitera de nuevo, el problema de la 'caja negra' de las redes neuronales. Los datos no son interpretables a simple vista y después de las transformaciones, no presentan toda la información potencial.

Para las futuras aplicaciones de las redes neuronales en sistemas urbanos se recomienda utilizar datos que representen la totalidad del fenómeno a estudiar. Se considera que las redes neuronales si tienen un gran potencial para predecir, pero

requiere de más estudios frente a su potencial para predecir el clima a corto plazo. Se considera que las redes neuronales tienen un excelente desempeño con los valores atípicos; pero en este caso, parecen haber sido ignorados y ajustados al promedio. Por otra parte, las redes neuronales requieren de una investigación y entendimiento del sistema a estudiar para su construcción.

11. Referencias

- Alberti, M. 2008. *Advances in Urban Ecology: Integrating Humans and Ecological Processes in Urban Ecosystems*. Page (Scienc+Social business Media, Ed.). I. Springer, Seattle, WA.
- Alcaldía Mayor de Bogotá, S. D. de P. 2016. *Plan Distrital de Desarrollo 2016-2020. Bogotá mejor para todos*.
- Amaya A. M. J. y Angel C. E. 2008. *Linea Base Ambiental 2008 Estado del Ambiente en Bogotá D. C.* :107.
- Angel, L., A. Ramirez, and E. Dominguez. 2010. *Espacio-Temporales De La Temperatura XXXIV*:12.
- Aparicio, L. S. 2010. *El impacto del transporte en el ordenamiento de la ciudad : el caso de Transmilenio en Bogotá* *Transport impact in urban planning : the case of Transmilenio in Bogota*:33–64.
- Baklanov, A., C. S. B. Grimmond, D. Carlson, D. Terblanche, X. Tang, V. Bouchet, B. Lee, G. Langendijk, R. K. Kolli, and A. Hovsepyan. 2017. *From urban meteorology, climate and environment research to integrated city services*. *Urban Climate* 23:330–341.
- Bernard, J., M. Musy, I. Calmet, E. Bocher, and P. Keravec. 2017. *Urban heat island temporal and spatial variations: Empirical modeling from geographical and meteorological data*. *Building and Environment* 125:423–438.
- Blake, R., A. Grimm, T. Ichinose, R. Horton, S. Gaffin, S. Jiong, D. Bader, and L. D. Cecil. 2011. *Urban climate: Processes, trends and projections*. Page (C. Tosenzweig, W. Solecki, S. Hammer, and S. Mehrotra, Eds.) *Climate Change and Cities: First Assessment Report of the Urban Climate Change Research Network*. Cambridge University Press, Cambridge, UK.
- Breuste, J. H. 2012. *Ecology in cities: man-made physical conditions*. *Urban ecology : patterns, processes, and applications*:17–31.
- Camperos, E. N. S., and A. Y. A. García. 2006. *Redes neuronales: conceptos fundamentales y aplicaciones a control automático*. Pearson Educación.
- Chapman, S., J. E. M. Watson, A. Salazar, M. Thatcher, and C. A. McAlpine. 2017a. *The impact of urbanization and climate change on urban temperatures : a systematic review*. *Landscape Ecology* 2.
- Chapman, S., J. E. M. Watson, A. Salazar, M. Thatcher, and C. A. McAlpine. 2017b. *The impact of urbanization and climate change on urban temperatures: a systematic review*. *Landscape Ecology* 32:1921–1935.
- Dimitrova, B., M. Vuckovic, K. Kiesel, A. Mahdavi, and B. Ecology. 2014. *Trees and the Microclimate of the Urban Canyon: A Case Study*. *Proceedings of the 2nd ICAUD International Conference in Architecture and Urban Design*:8–10.
- Distrital, S. D. P. S. 2017. *Análisis demográfico y proyecciones poblacionales de*

- Bogotá. Bogota D.C.
- Dixon, G. P., and T. L. Mote. 2003. Patterns and Causes of Atlanta ' s Urban Heat Island – Initiated Precipitation. American Meteorological Society 42.
- Dominguez, E., C. Dawson, A. Ramirez, and R. Abrahart. 2008. The Search for Orthogonal Hydrological Modelling Metrics: A Case Study of Twenty Monitoring Stations in Colombia. *Journal of Hydroinformatics* 39:561–563.
- Donges, N. 2018. Gradient Descent in a Nutshell. <https://towardsdatascience.com/gradient-descent-in-a-nutshell-eaf8c18212f0>.
- Fujii, H., K. Iwata, and S. Managi. 2017. How do urban characteristics affect climate change mitigation policies? *Journal of Cleaner Production* 168:271–278.
- Gago, E. J., J. Roldan, and J. Ordóñez. 2013. The city and urban heat islands : A review of strategies to mitigate adverse effects. *Renewable and Sustainable Energy Reviews* 25:749–758.
- Grimm, N. B., S. H. Faeth, N. E. Golubiewski, C. L. Redman, J. Wu, X. Bai, J. M. Briggs, N. B. Grimm, S. H. Faeth, N. E. Golubiewski, C. L. Redman, J. Wu, X. Bai, and J. M. Briggs. 2015. Global Change and the Ecology of Cities *Global Change and the Ecology of Cities*. Science (New York, N.Y.) 319:756–760.
- Grimmond, C. S. B., and T. Oke. 1998. 1999_Heat storage in urban areas_ Local-scale observations and evaluation of a simple model.pdf.
- Grimmond, C. S. B., and T. Oke. 1999. Aerodynamic Properties of Urban Areas Derived from Analysis of Surface Form:1262–1292.
- Hopps, K. 2018, July. Japan Heatwave 2018: Japan declares natural disaster- death toll mounts. *Express UK*:2.
- Hornik, K., M. Stinchcombe, and H. White. 1989. Multilayer Feedforward Networks are Universal Approximations *Neural Networks* 2 No 5, 359-366. Page Neural Networks.
- IDEAM. 2012. Caracterización Climática De Bogotá. Bogotá D.C.
- IDEAM. 2015. Nuevos escenarios para el Cambio Climático para Colombia 2011-2100. Page Ideam.
- IPCC. 2007. *Climate Change 2007: Impacts, adaptation and vulnerability*.
- Kassam, A. 2018, July. Canada Heatwave: more than 30 deaths reported as extreme weather continues. *The Guardian*:3. Quebec.
- Landsberg, H. E. 1981. *Urban Energy fluxes*. Page International Geophysics Series. New York.
- Leal Filho, W., L. Echevarria Icaza, A. Neht, M. Klavins, and E. A. Morgan. 2018. Coping with the impacts of urban heat islands. A literature based study on understanding urban heat vulnerability and the need for resilience in cities in a global climate change context. *Journal of Cleaner Production* 171:1140–1149.
- Lek, S., and J. F. Gue. 1999. Artificial neural networks as a tool in ecological modelling , an introduction 120:65–73.
- Liu, Z., C. Peng, W. Xiang, and D. Tian. 2010. Application of artificial neural networks in global climate change and ecological research : An overview.
- Loughner, C. P., D. J. Allen, D. Zhang, K. E. Pickering, R. R. Dickerson, and L. Landry. 2012. Roles of Urban Tree Canopy and Buildings in Urban Heat Island Effects : Parameterization and Preliminary Results. *American Meteorological society*:1775–1794.

- Maier, H. R., and G. . Dandy. 2001. Neural Network Based Modelling of Environmental Variables : A Systematic Approach. *Mathematical and Computer Modelling* 33:669–682.
- Mathew, A., S. Khandelwal, and N. Kaul. 2017. Investigating spatial and seasonal variations of urban heat island effect over Jaipur city and its relationship with vegetation , urbanization and elevation parameters. *Sustainable Cities and Society* 35:157–177.
- Mcdonnell, M. J., S. T. Pickett, and W. J. Cronon. 1993. Humans as components of ecosystems the ecology of subtle human effects and populated areas / Mark J. McDonnell, Steward T.A. Pickett, editors ; foreword by William J. Cronon.
- Memon, R. A., D. Y. C. Leung, and L. I. U. Chunho. 2008. A review on the generation , determination and mitigation of Urban Heat Island 20:120–128.
- Ministerio de Medio Ambiente y Desarrollos Sostenible. 2015. Informe Nacional de Calidad Ambiental Urbana: Áreas urbanas con población superior a 500.000 habitantes:92.
- Moawad, A. (n.d.). Neural Networks and Backpropagation explained in a simple way. <https://medium.com/datathings/neural-networks-and-backpropagation-explained-in-a-simple-way-f540a3611f5e>.
- Mohajerani, A., J. Bakaric, and T. Jeffrey-Bailey. 2017. The urban heat island effect, its causes, and mitigation, with reference to the thermal properties of asphalt concrete. *Journal of Environmental Management* 197:522–538.
- Montoya, W. J. 2014. Bogotá, urbanismo posmoderno y la transformación de la ciudad contemporánea. *Revista de geografía Norte Grande*:9.
- Oke, T. . 2004. INITIAL GUIDANCE TO OBTAIN REPRESENTATIVE METEOROLOGICAL OBSERVATION AT URBAN SITES. Canada.
- Oke, T. R. 1987. *Boundary Layer Climates*. Taylor & Francis Books, Inc.
- Olden, J. D., and D. A. Jackson. 2018. Illuminating the “ black box ”: A randomization approach for understanding variable contributions in artificial neural networks
Illuminating the ““ black box ””: a randomization approach for understanding variable contributions in artificial neural networks 3800.
- Olden, J. D., M. K. Joy, and R. G. Death. 2004. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data 178:389–397.
- Paul, M. J., and J. L. Meyer. 2001. STREAMS IN THE URBAN LANDSCAPE Michael. *Annual Review of Ecology and Systematics* 32:333–365.
- Planeación, S. D. de. 2013. Índice para la mitigación del Cambio Climático en Bogotá D.C. Bogotá D.C.
- Qiu, G. Y., Z. Zou, X. Li, H. Li, Q. Guo, C. Yan, and S. Tan. 2017. Experimental studies on the effects of green space and evapotranspiration on urban heat island in a subtropical megacity in China. *Habitat International* 68:30–42.
- Quetglas, A., F. Ordines, and B. Guijarro. 2006. The Use of Artificial Neural Networks (ANNs) in Aquatic Ecology.
- Rosenfeld, D. 2000. Suppression of rain and snow by urban and industrial air pollution. *Science* 287:1793–1796.
- Salata, F., I. Golasi, A. D. L. Vollaro, and R. D. L. Vollaro. 2015. How high albedo and traditional buildings’ materials and vegetation affect the quality of urban

- microclimate. A case study. *Energy and Buildings* 99:32–49.
- Sánchez Camperos, E. N., and A. Y. Alanís García. 2006. *Redes neuronales conceptos fundamentales y aplicaciones a control automático* / Edgar Nelson Sánchez Camperos y Alma Yolanda Alanís García.
- Secretaría Distrital De Movilidad. 2014. *Movilidad en cifras 2014*. Bogotá D.C.
- Seto, K. C., M. Fragkias, B. Guneralp, and M. K. Reilly. 2011. A Meta-Analysis of Global Urban Land Expansion. *Current Science* 101:1435–1439.
- Seto, K. C., B. Guneralp, and L. R. Hutyrá. 2012. Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. *Proceedings of the National Academy of Sciences* 109:16083–16088.
- Shanker, M., M. Y. Hu, and M. S. Hung. 1996. Effect of data standardization on neural network training. *Omega* 24:385–397.
- Shepherd, J. M. 2001. On Rainfall Modification by Major Urban Areas, Part 1, Observations from Space-borne Rain Radar Aboard TRMM:689–702.
- Souza, D. O. de, R. C. dos S. Alvalá, and M. G. do Nascimento. 2016. Urbanization effects on the microclimate of Manaus: A modeling study. *Atmospheric Research* 167:237–248.
- Taha, H. 1997. Urban climates and heat islands : albedo , evapotranspiration , and anthropogenic heat 25:99–103.
- Touchaei, A. G., H. Akbari, and C. W. Tessum. 2016. Effect of increasing urban albedo on meteorology and air quality of Montreal (Canada) - Episodic simulation of heat wave in 2005. *Atmospheric Environment* 132:188–206.
- Vuckovic, M., K. Kiesel, and A. Mahdavi. 2017. Studies in the assessment of vegetation impact in the urban context. *Energy and Buildings* 145:331–341.
- Wilson, W. 2011. *Emissions and Urban Air*. Page Constructed Climate: A Primer on Urban Environments. University of Chicago Press, Chicago.
- Wong, N. H., A. Y. K. Tan, P. Y. Tan, and N. C. Wong. 2009. Energy simulation of vertical greenery systems. *Energy & Buildings* 41:1401–1408.
- Yamaguchi, Y., Y. Shimoda, and M. Mizuno. 2007. Proposal of a modeling approach considering urban form for evaluation of city level energy management. *Energy and Buildings* 39:580–592.
- Yao, R., L. Wang, X. Gui, Y. Zheng, H. Zhang, and X. Huang. 2017. Urbanization Effects on Vegetation and Surface Urban Heat Islands in China's Yangtze River Basin. *Remote Sensing* 9:540.
- Zhang, W. 2010. *Computational Ecology: Artificial Neural Networks And Their Applications*. Singapore.