



Universidad Autónoma de Querétaro  
Facultad de Ingeniería  
Maestría en Ciencias en Instrumentación  
y Control Automático

**Modelado y Predicción de la temperatura interna en edificios de salones de clase**

**TESIS**

Que como parte de los requisitos para obtener el grado de  
Maestro en Ciencias en Instrumentación y Control Automático

**Presenta:**

José Alberto García Chávez

**Dirigido por:**

Dr. José Gabriel Ríos Moreno

**SINODALES**

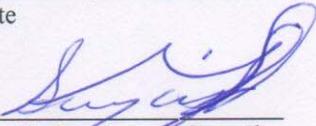
Dr. José Gabriel Ríos Moreno  
Presidente

Dr. Mario Trejo Perea  
Secretario

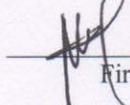
Dr. Eusebio Ventura Ramos  
Vocal

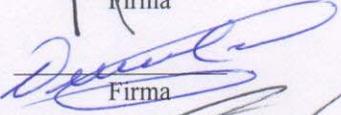
Dr. Enrique Rico García  
Suplente

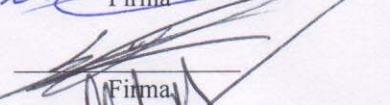
Dr. Mario Enrique Rodríguez García  
Suplente

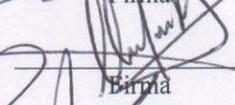
  
Dr. Aurelio Domínguez González  
Director de la Facultad

  
Firma

  
Firma

  
Firma

  
Firma

  
Firma

  
Dr. Ifineo Torres Pacheco  
Director de Investigación y Posgrado

## Resumen

El confort térmico es un factor importante que determina la productividad, la salud y el bienestar de los ocupantes. El exceso de la demanda de energía eléctrica debido a los sistemas de calefacción, ventilación y aire acondicionado (HVAC) en edificios inteligentes requieren de la predicción y control de la temperatura interna, lo cual representa un impacto positivo hacia la sustentabilidad energética. El objetivo principal, es investigar en qué medida los modelos lineales autoregresivos con entrada externa (ARX) y los modelos de redes neuronales artificiales (RNA) se podrían utilizar para predecir la temperatura interna en edificios de manera óptima. En particular se muestran los resultados obtenidos en salones de clase de la Universidad Autónoma de Querétaro, U.A.Q., México. Temperatura externa, humedad relativa externa, velocidad del viento, radiación solar y la humedad relativa interna fueron utilizadas como variables de entrada. El algoritmo implementado para la predicción de la RNA fue Levenberg-Marquardt, la validación de los datos se realizó por medio de análisis de varianza (ANOVA) y fue comparado con los modelos ARX. Los resultados obtenidos mostraron que los modelos RNA dan una mejor predicción de la temperatura interna que los modelos ARX, obteniéndose los mejores resultados con la RNA (6,4,1) con un coeficiente de determinación de 0.9647, un porcentaje promedio del error absoluto de 0.0565 y un error cuadrático medio de 0.0609.

**Palabras clave:** Modelado de temperatura, edificios inteligentes, confort térmico, redes neuronales artificiales, modelos autoregresivos, Levenberg-Marquadt, ANNOVA, sistemas HVAC.

## Summary

Thermal comfort is an important fact to determine the productivity, health and the welfare of the occupants. Due to the excess demand of the electrical power by the heating, ventilation and the air-Conditioning (HVAC) systems at intelligent buildings, it is required to predict the control of the internal temperature, which has a positive impact in the energy sustainability inside a room. The main purpose of this research is to look at how the autoregressive (ARX) input and the artificial neural network model (ANN) can be used to analyze the results of the internal temperature measurements. In this particular case, the data derived from the model was elicited from some classrooms of Universidad Autónoma de Queretaro, Mexico. The temperature and humidity external, wind velocity, solar radiation, internal humidity were used as input variables. Levenberg-Marquadt algorithm was then applied to predict the ANN, and the data validity was done by means of ANOVA method also compared with ARX models. The final results showed that the ANN models are better to predict the temperature than the ARX models, so the best models were given by the ANN (6,4,1) with a coefficient of determination of 0.9647, an average absolute error rate percentage of 0.0565 and mean square error of 0.0609.

**Keywords:** Modelling temperature, intelligent buildings, Thermal comfort, Artificial neural networks models, Autoregressive models, Levenberg-Marquadt, ANNOVA, HVAC systems.

## Dedicatorias

*“A mi familia, amigos y seres muy queridos”.*

## **Agradecimientos**

A mi familia ya que sin ellos hubiera sido imposible llegar a este punto. A mi mamá por ser una persona que siempre me ayuda a seguir adelante y motivándome día a día.

Gracias a mi asesor el Dr. José Gabriel Ríos Moreno por su apoyo y colaboración en el presente trabajo, por su gran paciencia, su comprensión.

Gracias a mi co asesor el Dr. Mario Trejo Perea por su apoyo en la elaboración de mi proyecto de investigación y por el gran aporte de ideas en el trabajo.

A mis compañeros de la maestría ya que en todo este tiempo se genera un lazo mutuo de amistad y fraternidad para el desarrollo y mejora continua de nuestros conocimientos.

Gracias a todas las personas que de cierta manera invirtieron tiempo en mi vida para ayudarme a salir adelante.

Y sobre todo al Dr. Gilberto Herrera Ruiz, por servirme de ejemplo profesional y personal, ojala hubiera miles de personas como él para hacer de México un mejor país.

## Índice

|   | Página |
|---|--------|
| Resumen.....  | i      |
| Summary.....  | ii     |
| Agradecimientos.....  | iii    |
| Dedicatorias.....   | iv     |
| Índice.....   | v      |
| Índice de figuras.....  | vi     |
| Índice de tablas.....   | vii    |
| <b>Capítulo I</b>   |        |
| 1. Introducción.....  | 1      |
| 1.1. Descripción del Problema.....                                      | 6      |
| 1.2. Justificación.....   | 10     |
| 1.3. Objetivos.....   | 11     |
| 1.3.1. Objetivo general.....  | 11     |
| 1.3.2. Objetivos específicos.....                                       | 11     |
| 1.4. Hipótesis.....   | 12     |
| <b>Capítulo II</b>  |        |
| 2. Consideraciones teóricas.....  | 13     |
| 2.1. Valoración del confort térmico.....                                | 13     |
| 2.1.1. Índice de valoración del medio (IVM).....                        | 13     |
| 2.2. Modelos de predicción de la temperatura interior en edificios..... | 16     |
| 2.3. Estructura del modelo ARX.....                                     | 17     |
| 2.3.2. Proceso de identificación de un sistema ARX.....                 | 22     |
| 2.4. Estructura del modelo RNA.....                                     | 24     |
| 2.4.1. Redes neuronales Feedforward.....                                | 26     |
| 2.5 Entrenamiento.....  | 32     |
| 2.5.1. Algoritmos de entrenamiento supervisado.....                     | 32     |
| 2.5.2. Aprendizaje en línea y fuera de línea.....                       | 34     |

### **Capítulo III**

|   | Página |
|---|--------|
| 3. Metodología.....                           | 36     |
| 3.1. Localización del sitio experimental..... | 36     |
| 3.2. Mediciones de campo.....                 | 37     |
| 3.3. Medidas de Precisión .....               | 42     |

### **Capítulo IV**

|                                    |    |
|------------------------------------|----|
| 4. Resultados y discusión.....     | 45 |
| 4.1. Selección de los modelos..... | 45 |
| 4.2. Conclusiones.....             | 57 |
| Bibliografía.....                  | 59 |

### **Anexos**

|                                       |           |
|---------------------------------------|-----------|
| <b>Publicaciones científicas.....</b> | <b>65</b> |
|---------------------------------------|-----------|

## Índice de figuras

| Figura  | Página |
|---|--------|
| 2.1 Diagrama de bloques usando 5 variables para la predicción interna de la temperatura en salones de clase.....                        | 18     |
| 2.2 Modelo de una red neuronal artificial.....  | 25     |
| 2.3 Modelo de una red neuronal para el desarrollo de aprendizaje.....   | 27     |
| 2.4 Red neuronal artificial con alimentación inicial.....   | 35     |
| 3.1 Localización del sitio de estudio, Edificio H de posgrado de la facultad de Ingeniería de la Universidad Autónoma de Querétaro..... | 37     |
| 3.2 Estructura del salón de clase (Vista desde el lado sur).....  | 38     |
| 3.3 Vista del edificio (dimensiones en metros).....   | 39     |
| 3.4 Diseño del sensor de monitoreo de temperatura y humedad.....  | 40     |
| 3.5 Diseño de comunicación entre CEA y HOBO Pro V2. (Vista lateral derecha).....  | 41     |
| 4.1 Comparación de los datos medidos contra los modelos ARX y RNA de la temporada de verano.....  | 47     |
| 4.2 Comparación del error de los modelos ARX, RNA y regresión de la temporada de verano.....  | 49     |
| 4.3 Comparación de los datos medidos contra los modelos ARX y RNA de la temporada de invierno.....                                      | 51     |
| 4.4 Comparación del error de los modelos ARX, RNA y regresión de la temporada de invierno.....  | 52     |

## Índice de tablas

| Tabla   | Página |
|---|--------|
| 1.1 Recomendación para un confort estable.....  | 7      |
| 1.2 Rangos de confort térmico óptimo.....   | 9      |
| 2.1 Parámetros de confort de Fanger.....  | 14     |
| 2.2 Aislamiento térmico según el tipo de vestimenta, ISO 7730.....  | 15     |
| 3.1 Rangos de operación del data logger HOBO pro V2.....  | 40     |
| 4.1 Comparación del error estimado de los diferentes modelos ARX y RNA en la temporada de verano.....                                     | 46     |
| 4.2 Comparación del error estimado de los diferentes modelos ARX y RNA en la temporada de invierno.....                                   | 50     |
| 4.3 Comparación mediante ANOVA de los datos medidos contra los datos comparados de los modelos ARX y RNA de la temporada de verano.....   | 53     |
| 4.4 Comparación mediante ANOVA de los datos medidos contra los datos comparados de los modelos ARX y RNA de la temporada de invierno..... | 54     |
| 4.5 Comparación de la media de los tratamientos 1,2 y 1,3.....  | 56     |

# CAPÍTULO I

## 1. Introducción

A través de la historia la educación ha sido un factor importante ya que es vital para la formación del ser humano en múltiples disciplinas. La tecnología en algunas ocasiones de éste transcurso ha ido a la par con la educación facilitándola y ayudándola a funcionar como tal; actualmente la educación está permanentemente ceñida a la tecnología permitiendo así mejorar las condiciones y el nivel de aprendizaje del estudiante. Para poder lograr todos estos objetivos los alumnos y ocupantes deben de disponer de una zona de confort térmica agradable, para ello se necesita un espacio en donde la temperatura sea la más óptima para el aprendizaje integral.

Cuando se analiza la ventilación de los edificios hay que considerar como problema básico el diseño térmico del mismo, el emplazamiento, orientación, las características térmicas de los materiales y la protección contra la radiación solar, fundamentalmente las superficies vidriadas; esto debido a que hoy en día a nivel global, los edificios son responsables de aproximadamente el 40 del consumo anual de energía eléctrica en todo el mundo, la cual produce consecuencias negativas en el medio ambiente (Ríos et al., 2007; Venkatasubramanian et al., 2003; Jiménez et al., 2008). El alto consumo de energía de los sistemas de calefacción, ventilación y aire acondicionado (HVAC) es debido al uso de métodos ineficientes, secuencias de operación inadecuadas y fallas en los sistemas (Jiménez et al., 2008).

Es importante considerar que la temperatura radiante en un espacio afecta a la comodidad térmica (Silva et al., 2007). En un cuarto o salón de clase no pueden sentirse comfortable los ocupantes, si las superficies y los objetos irradian mucho calor; mientras que un cuarto con aire acondicionado elevado las superficies y los objetos pueden ser muy fríos. Para discutir el confort térmico en un espacio, se ha introducido el concepto de temperatura operativa. La temperatura operativa es una combinación de la temperatura demasiado cálida y la temperatura del aire.

La temperatura radiante mala es la temperatura media de los objetos y de las superficies en nuestros alrededores, que irradian demasiado calor a nuestros cuerpos (Nilsson, 2003).

Investigaciones recientes y estudios experimentales han demostrado que existe un ahorro potencial de energía de alrededor del 30% mediante la mejora de la gestión energética al establecer un funcionamiento correcto u óptimo de los sistemas HVAC en edificios (Aal Faraj y Al Haidary, 2006; Trčka y Hensen, 2010; García Chávez et al., 2011).

Ingenieros y arquitectos han influenciado el uso de la energía de los nuevos edificios de varias maneras; a través del diseño exterior, el uso de nuevos materiales, la selección del equipo de HVAC y la especificación de secuencias de operación; sin embargo, una vez que el edificio ha sido construido, el consumo de energía es decidido principalmente por su control, mantenimiento, y uso del edificio por los ocupantes. El ahorro energético se puede lograr con el uso de sistemas de control basados en modelos de predicción de temperatura al interior de los edificios, los cuales pueden tener una estimación de al menos 15 a 30 minutos de anticipación y aplicando secuencias de control eficiente podrían brindar un ambiente de confort óptimo para los ocupantes de los edificios (García Chávez et al., 2011; Omer, 2008). Los modelos basados en métodos estadísticos y no estadísticos proporcionan una base técnica importante para elevar el nivel de confort requerido para los edificios inteligentes (Kaklauskas et al., 2010; Trčka y Hensen, 2010, García Chávez et al., 2011).

Debido a que la temperatura al interior de los edificios se ve afectada por diversas variables internas y externas, es importante basar las predicciones en normas estandarizadas y modelos que cuenten con un mayor número de variables de entrada, esto con el fin de obtener la precisión requerida en la estimación de las variables de interés. Algunas variables que afectan al clima interior están directamente relacionadas con las condiciones climáticas externas como la temperatura, radiación solar, humedad del aire, velocidad y dirección del viento (Mui et al., 2010; Chen, 2001).

En recientes investigaciones, varios autores han dedicado tiempo al estudio de modelos matemáticos, debido a que son una herramienta eficiente para la transformación de datos en información clave para la estimación y predicción de la temperatura, energía y detección de fallas en los sistemas HVAC (Loveday y Virk, 1992; González et al., 2005; Chen, 2002, 2003); destacando los modelos lineales autoregresivos, (Jiménez et al., 2008), modelos físicos, (Castañeda et al., 2006; Lafont y Balmat, 2002), así como los modelos de redes neuronales artificiales (Ferreira et al., 2002; Myhre et al., 2003; Kalogirou, 2010), mejorando el control en los sistemas HVAC, generando un mayor ahorro de energía eléctrica, (Loveday y Virk, 1992; Chen, 2001; Kaklauskas et al., 2010; Mui et al., 2010; Trčka y Hensen, 2010).

La estimación de la temperatura interna en edificios es una tarea complicada y muy importante, la cual puede ser abordada con dos clases diferentes de modelos: estadísticos y no estadísticos, (U.S. Department of Energy, 2004; Trčka y Hensen, 2010). El desarrollo de modelos mediante RNA, han demostrado que tienen la capacidad de reconocimiento y aprendizaje en la predicción de temperatura (Gouda y Danaher, 2002; Chen y Athienitis, 2003; González y Zamarreño, 2005; Kalogirou, 2010). Las RNA son muy adecuadas para la solución de problemas que requieren un conocimiento difícil de precisar. En este sentido, pueden ser tratadas como uno de los métodos no lineales y estadísticos con manejo multivariable (Ferreira et al., 2002; Gouda y Danaher, 2002; Myhre y Pettersen, 2003; Kalogirou, 2010).

Es posible estimar la temperatura operativa en un edificio usando otras variables de medición, tales como temperatura del aire de interior, el uso de la corriente eléctrica, temperatura al aire libre, la hora, temperaturas de la pared y flujo de la ventilación con el uso de dichos modelos (Mechaqrane y Zouak, 2004). En los últimos años, numerosas investigaciones han tratado de responder a las demandas de confort térmico y el ahorro energético.

Una herramienta para mejorar son las estructuras de los modelos matemáticos precisos y simples para predecir el comportamiento de las variables atmosféricas. En los últimos 20 años se ha estudiado el clima del invernadero usando modelos matemáticos, físicos o mecanicistas (Bot, 1983; Deltour et al., 1985; Wang y Boulard, 2000), o modelos empíricos del tipo caja negra, como los de autoregresión con variables exógenas (ARX) (Boaventura Cunha, et al., 1996; Uchida-Frausto et al., 2003).

Los métodos auto regresivos permiten construir modelos usando la relación entre la entrada  $u(t)$  y la salida  $y(t)$  del sistema utilizando técnicas de identificación de parámetros, como los modelos auto regresivos con entrada externa (ARX). (Uchida et al., 2003).

De acuerdo con (López, 2007) realizó un estudio utilizando modelos lineales ARX para la predicción y el comportamiento de la temperatura en el interior de un invernadero, las variables utilizadas fueron temperatura del aire, radiación solar, velocidad del viento y humedad relativa, tomando muestras cada 5 minutos durante un ciclo de cultivo, se evaluaron modelos ARX para determinar el mejor modelo usando el criterio de información y el error de predicción final de Akaike, (Akaike, 1974), los resultados mostraron que los modelos ARX de segundo orden o superior predicen de manera adecuada el comportamiento de la temperatura al interior del invernadero.

El trabajo presentado por (Sinha, 2001) muestra una modificación al modelo ARX con el fin de incluir un método de promedio móvil como una herramienta eficaz para la predicción de la temperatura ambiente, usando como variables la radiación solar y la carga térmica. La modificación dio lugar a un método muy robusto, capaz de predecir resultados casi exactos. La ventaja de este sistema es que es viable en zonas donde los datos meteorológicos no se encuentran disponibles o son inciertos.

Hay un especial interés en el área para el uso de las redes neuronales artificiales (RNA) para la predicción y control de temperatura al interior de los edificios tomando en consideración parámetros y variables climáticas.

Los modelos de RNA han demostrado ser estructuras no lineales acertadas del modelo de Caja negra, los usos en la identificación han atraído un interés cada vez mayor en estos últimos años (Thomas et al., 2007). Los modelos de RNA han demostrado ser estructuras no lineales acertadas del modelo de Caja negra sirviendo para la identificación, han atraído un interés cada vez mayor estos últimos años (Ruano et al., 2006; Soleimani-Mohsen et al., 2006). Hay también otras estructuras del modelo no lineal que se pueden utilizar para la valoración, tales como las redes radiales de la función de base, redes recurrentes, y modelos difusos.

Trujillano (2003), realizó un estudio de comparación de probabilidades mediante modelos de RNA con el software Acute Physiology and Chronic Health Evaluation II (APACHE II) y la regresión logística (RL) para el análisis de la capacidad de predicción de mortalidad hospitalaria, utilizando las variables del sistema APACHE II; los resultados mostraron que las redes RNA en comparación con una regresión lógica dan mejores resultados.

Montero (2009), desarrolló un modelo para la predicción del consumo de la energía eléctrica y de gas licuado a presión (GLP) empleando una RNA, la temperatura ambiente (máxima, mínima, media, máxima absoluta y mínima absoluta), la velocidad del viento, el total de lluvias, la presión atmosférica, la humedad relativa, la nubosidad y el nivel ocupacional se utilizaron como variables de entrada al modelo, obteniendo resultados de más del 90% de precisión, con una desviación promedio en la predicción del consumo de energía eléctrica del 0.6% y una desviación estándar del 4%; para el caso del GLP la desviación media fue menor al 1%, con una desviación estándar del 1.3%.

El propósito de este trabajo es determinar la estructura apropiada de los modelos ARX y RNA para predecir la temperatura interior de un edificio de salones de clase de manera óptima. Por medio del estudio de las variables climáticas externas que pueden ser incluidas en los modelos para lograr una mejor estimación. El modelo dinámico puede convertirse en una gran alternativa práctica para la predicción interna en edificios, lo cual permitirá incrementar el confort térmico de los ocupantes del edificio y al mismo tiempo, reducir el exceso de consumo de energía eléctrica debido a los sistemas HVAC.

### **1.1. Descripción del problema**

Una meta importante de los edificios inteligentes es mejorar la comodidad de los ocupantes y la seguridad con una reducción global en el consumo de energía, (Wong, et al., 2005). La calidad del aire interior y el confort térmico deben ser asegurados por medio de una calefacción adecuada y la ventilación de los espacios.

El consumo de energía eléctrica debido a los sistemas de HVAC en edificios industriales y comerciales constituye el 50% del consumo mundial de energía (Imbabi, 1990). Los elevados consumos de energía generados por los sistemas HVAC están relacionados con usos de sistemas ineficientes, secuencias de operación y fallas en el sistema. Investigaciones experimentales y estudios teóricos han demostrado que es posible generar un ahorro potencial gracias a la mejora de la gestión de la energía, estableciendo el funcionamiento correcto u óptimo de los sistemas HVAC en edificios comerciales; y tal consumo energético puede reducirse entre un 20% a 30 % y al mismo tiempo solucionar algunos problemas de confort (Fanger, 1972).

La temperatura óptima, también llamada comúnmente temperatura neutra representa un punto en la escala térmica, por ello es más conveniente hablar de un rango de temperatura en cual el individuo expresa satisfacción térmica con el ambiente (Szokolay, 1984).

En lugares de centros de trabajo, tales como oficinas, cuartos de control y centros de cómputo y laboratorios, etc., en los que se necesita el uso de una ventilación artificial para el mejoramiento del confort térmico de los trabajadores en el área laboral, para llevarlo a cabo se recomienda tomar en consideración las siguientes variables: humedad relativa, temperatura relativa y la velocidad del aire considerando los siguientes puntos:

- Humedad relativa entre el 20% y 60%.
- Temperatura del aire de  $22^{\circ}\text{C} \pm 2^{\circ}\text{C}$  para épocas de ambiente frío y  $24.5 \pm 1.5^{\circ}\text{C}$  para épocas calurosas.
- Velocidad media del aire que no exceda de 0.15 m/s, en épocas de ambiente frío, y de 0.25m/s en épocas calurosas.
- Se recomienda que la renovación del aire no sea inferior a 5 veces por hora.

Un mínimo absoluto de 8.5 m<sup>3</sup> /h por persona en el interior de un recinto, esto es para mantener la concentración de CO<sub>2</sub> por debajo de 2500 ppm. Es la mitad del límite de exposición permisible en un ambiente laboral (Ryan, 1993; Norma Oficial Mexicana, 1999). El ser humano es homeotérmico, o de sangre caliente, con mecanismos internos que conservan una temperatura estable en su cuerpo; entre estos están relacionados con la producción de calor dentro del cuerpo, así como su disipación (Tabla 1.1).

**Tabla 1.1.** Recomendación para un confort estable.

| <b>Recomendaciones para un confort óptimo</b> | <b>Unidad por persona</b> |
|---|---------------------------|
| Para los salones de clase:                    | 25.5 m <sup>3</sup> /h    |
| Para oficinas:                                | 34.0 m <sup>3</sup> /h    |
| Para hospitales:                              | 42.5 m <sup>3</sup> /h    |

La temperatura normal del cuerpo de una persona varía dependiendo de su sexo, su actividad reciente, el consumo de alimentos y líquidos, la hora del día y, en las mujeres, de la fase del ciclo menstrual en la que se encuentren. La temperatura corporal normal, de acuerdo con la Asociación Médica Americana puede oscilar a los 36.5 °C y 37.2 °C.

En el cuerpo se produce calor como subproducto del metabolismo y se pierde constantemente por evaporación, radiación, conducción y por convección, la exposición prolongada a temperaturas más bajas de los normal, esto hace que se estimule la glándula tiroides y aumenta su producción, al tener una pérdida de calor en el organismo este tiene un efecto inhibitor en los mecanismos de producción y se observa una reacción inversa, otro método de liberación es la sudoración, realiza una pérdida considerable por evaporación de la humedad de la piel.

Por las características del territorio nacional, en México predominan los climas cálidos, lo cual, junto con los diseños inadecuados a la región, obliga al uso de sistemas de aire acondicionado.

Localidades con un clima cálido seco ocupan casi dos terceras partes del territorio nacional, con respecto a los estudios de (Auliciems y Szokolay, 1999), a través de los cuales se desarrolló en la Tabla 1.2, en donde se definen los rangos de confort térmico para varias ciudades de la República Mexicana. Aplicando la fórmula de Auliciems:

$$\begin{aligned} T_n &= 17.6 + 0.31 T_m \\ Z_c &= T_n \pm 2.5^\circ C \end{aligned} \quad (1)$$

Donde:

$T_n$ : Temperatura neutra.

$T_m$ : Temperatura media anual o mensual.

$Z_c$ : Zona de confort.

**Tabla 1.2.** Rangos de confort térmico óptimo.

|                       | Rangos de Confort para varias ciudades de la República Mexicana |           |             |
|-----------------------|---|-----------|-------------|
|                       | <i>min.</i>   | <i>Tn</i> | <i>máx.</i> |
| Chihuahua, Chihuahua  | 20.8°   | 23.3°     | 25.8°       |
| Ciudad de México      | 19.8°   | 22.3°     | 24.8°       |
| Cuernavaca, Morelos   | 21.6°   | 24.1°     | 26.6°       |
| Guadalajara, Jalisco  | 21.0°   | 23.5°     | 26.0°       |
| Hermosillo, Sonora    | 22.6°   | 25.1°     | 27.6°       |
| La Bufa, Zacatecas    | 19.3°   | 21.8°     | 24.3°       |
| Monterrey, Nuevo León | 21.9°   | 24.4°     | 26.9°       |
| Puebla, Puebla        | 20.2°   | 22.7°     | 25.2°       |
| Toluca, México        | 18.9°   | 21.4°     | 23.9°       |
| Veracruz, Veracruz    | 22.9°   | 25.4°     | 27.9°       |
| Villahermosa, Tabasco | 23.6°   | 26.1°     | 28.6°       |

Las normas oficiales emitidas ya sea por la Secretaría del Medio Ambiente Recursos Naturales y Pesca (SEMARNAP) o por la Secretaría del Trabajo y Previsión Social (STPS), vigentes en nuestro país, no establecen el valor permisible máximo de CO<sub>2</sub> en recintos cerrados destinados a aulas. En la Norma Oficial Mexicana (NOM-001-STPS-1999), edificios, locales, instalaciones y áreas en los centros de trabajo, condiciones de seguridad e higiene; se proporciona una guía de referencia denominada "ventilación de confort". Es importante considerar que la temperatura radiante en un espacio afecta a la comodidad térmica (Silva et al., 2007). En un cuarto o salón de clase no pueden sentirse en un ambiente confortable los ocupantes, si las superficies y los objetos irradian mucho calor; mientras que un cuarto con aire acondicionado elevado puede ser muy frío si las superficies y los objetos son fríos. Para discutir el confort térmico en un espacio, se ha introducido el concepto de temperatura operativa. La temperatura operativa es una combinación de la temperatura demasiado cálida y la temperatura del aire. La temperatura radiante mala es la temperatura media de los objetos y de las superficies en nuestros alrededores, que irradian demasiado calor a nuestros cuerpos (Ryan, 1993).

## 1.2. Justificación

El confort térmico es un resultado integrado entre el bienestar climático del ocupante en su medio ambiente. Las condiciones ambientales se perciben como cómodas, cuando no se desea ningún cambio y cuando el funcionamiento del tema no es interferido con por estas condiciones (Mui et al., 2010).

El ambiente de operación de una edificación y los productos empleados pueden crear un ambiente en el que se pueden producir emisiones y reacciones químicas complejas. Las superficies más frías de una pared pueden aumentar su nivel de humedad relativa local, facilitando las emisiones generadas por el material de recubrimiento de la pared. La humedad en los pisos de hormigón facilita la degradación por sustancias alcalinas del di-etil-hexil-ftalato (DEHP), un plastificante empleado en los pisos de policloruro de vinilo (PVC) y en otros productos de este material (Bornehag et al., 2004).

Los problemas causados por la calidad de confort térmico debido a un ambiente interior poco óptimo que es ocasionado al uso ineficiente de los sistemas HVAC, generando una reducción en el desempeño y resultados de los ocupantes del edificio. El consumo potencial de la energía eléctrica es debido al uso excesivo de los sistemas de HVAC, por lo cual es necesario el uso de sistemas de predicción de la temperatura interna y de control para la reducción considerable del consumo y así garantizar un confort térmico.

Un factor importante que afecta la eficiencia de los sistemas HVAC en los edificios es el hecho de que la mayoría de los sistemas están configurados para operar en el diseño, mientras que las cargas térmicas reales son variables por lo que afectan al sistema en el tiempo.

Dentro del diseño sustentable cada vez abarca más diversos aspectos; como es el desarrollo y creación de construcciones verdes que ayuden a generar edificaciones amigables con el entorno. El rápido crecimiento en la adopción de diseños sustentables resulta una respuesta directa a la gran demanda de construcciones verdes por parte de los ocupantes. Siendo los edificios la principal fuente de emisión de carbono.

### **1.3. Objetivos**

#### **1.3.1. Objetivo general**

Determinar la estructura apropiada de los modelos ARX y RNA para predecir la temperatura interior de un edificio de salones de clase de manera óptima, por medio del estudio de las variables climáticas externas que pueden ser incluidas en los modelos para lograr una mejor estimación.

#### **1.3.2. Objetivos particulares**

- Determinar la estructura adecuada de un modelo predictor de la temperatura al interior de un edificio, comparando modelos ARX con modelos RNA.
- Estudiar las variables del clima exterior e interior que deben incluirse en los modelos ARX y RNA para poder lograr una mejor estimación de la temperatura interna de un edificio de salones de clase.
- Determinar los modelos que evalúe con mayor precisión la temperatura interna de un edificio con al menos de 15-30 minutos de adelanto.
- Validar los datos de las RNA por medio de análisis de varianza y compáralos con los modelos ARX para determinar cuáles modelos presenten un menor error de predicción de la temperatura interna.

### **1.4. Hipótesis**

Mediante los modelos ARX y RNA se puede predecir la temperatura al interior de un edificio con una estimación de predicción de 15 a 30 minutos; con lo cual se generan secuencias de control óptimas y con ello brindar un confort térmico a los ocupantes y al mismo tiempo reducir potencialmente el consumo de la energía eléctrica por el uso excesivo de los sistemas de HVAC.

## **CAPÍTULO II**

### **2. Consideraciones teóricas**

Actualmente la importancia del confort térmico en edificios ha ido en aumento, debido a que la mayoría de los ocupantes de oficinas, hospitales, escuelas, edificios, ven sus actividades disminuidas debido a la falta de un área de trabajo ventilada de manera óptima (Ljung, 1994).

#### **2.1. Valoración del confort térmico**

Es de gran interés la estimación del confort térmico la cual se desarrolló como una consecuencia del manejo de técnicas de acondicionamiento del aire cuyo objetivo principal era el lograr que las personas se sintieran confortables y precisamente por el uso de métodos de predicción.

El confort térmico puede definirse como la manifestación subjetiva de conformidad o satisfacción con el medio ambiente térmico existente, la cual es difícil de conseguir en un número de personas, cualesquiera que sean las condiciones ambientales de referencia, la totalidad de las mismas manifiesten sentirse confortables en una situación microclimática dada.

##### **2.1.1. Índice de valoración del medio (IVM)**

Este método consigue integrar todos los factores que determinan el confort térmico ofreciendo el porcentaje de personas insatisfechas (PPI) con las condiciones en las condiciones que el ambiente térmico en las que se desarrolla la actividad (Tabla 2.1). El IVM de Fanger utiliza la siguiente escala la cual se atribuye el confort térmico.

**Tabla 2.1.** Parámetros de confort de Fanger.

| <b>Rangos</b> | <b>Escala numérica de confort de Fanger</b> |
|---------------|---|
| -3            | Muy frío                                    |
| -2            | Frío  |
| -1            | Ligeramente frío                            |
| 0             | Neutro (confortable)                        |
| +1            | Ligeramente caluroso                        |
| +2            | Caluroso                                    |
| +3            | Muy caluroso                                |

Los parámetros que utiliza Fanger para la utilización de su escala son:

- Características de la vestimenta: aislamiento y área total del mismo.
- Características del tipo de trabajo: carga térmica metabólica y velocidad del aire (Velocidad debida al movimiento del cuerpo respecto al aire).
- Características del ambiente: temperatura seca, radiación, humedad, y velocidad del aire (velocidad del aire con respecto al cuerpo si estuviera quieto).

Las características térmicas de la vestimenta se miden en la unidad denominada “clo” ( $1 \text{ clo} = 0.155 \text{ m}^2 \text{ }^\circ\text{C}/\text{W}$ ) que se define como el aislamiento necesario para mantener confortable a una persona que desarrolle una actividad sedentaria (menos de  $60 \text{ W}/\text{m}^2$ ) a una temperatura de  $21^\circ\text{C}$ .

En la Tabla 2.2 se indica los valores del aislamiento térmico de la vestimenta de acuerdo con la norma ISO 7730.

**Tabla 2.2.** Aislamiento térmico según el tipo de vestimenta, ISO 7730.

| <b>Tipo de vestimenta</b>  | <b>Aislamiento térmico<br/>(CLO)</b> |
|--|--------------------------------------|
| Desnudo  | 0.0                                  |
| En pantalones cortos   | 0.1                                  |
| Vestimenta tropical en exteriores: camisa abierta con mangas cortas, pantalones cortos, calcetines y sandalias                               | 0.3                                  |
| Ropa ligera de verano: camisa ligera de mangas cortas, pantalones, calcetines y zapatos.   | 0.5                                  |
| Ropa de trabajo: camiseta, camisa con mangas largas, pantalones de vestir, calcetines y zapatos.   | 0.8                                  |
| Ropa de invierno y de trabajo en interiores: camiseta, camisa manga larga, calcetines de lana y zapatos.                                     | 1.0                                  |
| Vestimenta completa y de trabajo en interiores: camiseta, camisa de manga larga, chaleco, corbata, pantalones de lana, calcetines y zapatos. | 1.5                                  |

Para determinar el calor que genera el cuerpo en la realización de una actividad es necesario considerar tanto el calor producido para ejecutarla como el generado por el metabolismo basal. El metabolismo se mide en una unidad específica nombrada "*met*" que se define como el metabolismo de una persona sentada sin una actividad especial, ecuación (2).

$$1 \text{ met} = 58.1 \text{ W} / \text{m}^2 = 90 \text{ kcal} / \text{h} \quad (2)$$

El confort térmico se define en rangos de temperaturas operativas, las cuales proporcionan condiciones climáticas aceptables para la gran mayoría en el medio ambiente, combinando ciertos elementos como son la temperatura del aire y la temperatura media radiante; la cual, los ocupantes encuentran térmicamente aceptable (Sargent, 2001). En un ambiente cerrado hay seis principales elementos que condicionan la percepción de la calidad térmica del medio ambiente: temperatura del aire ( $T$ ), radiación solar ( $R_s$ ), velocidad del viento ( $W_v$ ), humedad relativa ( $R_h$ ), promedio de la velocidad del aire a través del tiempo ( $V_a$ ) y la ocupación ( $O_c$ ) (Kalogirou, 2010 y Sinha, 2001).

En esta investigación se plantean las siguientes variables de entrada: temperatura externa ( $T_o$ ), humedad relativa externa ( $R_{ho}$ ), velocidad del viento ( $W_s$ ), radiación solar ( $S_r$ ), y la humedad relativa interna ( $R_{hi}$ ); siendo la variable de salida la temperatura interna ( $T_i$ ) (Figuras 2.1 y 2.4).

## **2.2. Modelos de predicción de la temperatura interior en edificios**

Se debe tener en cuenta el rendimiento de las redes neuronales en el pronóstico en comparación con el uso de los métodos estadísticos bien establecidos. Hay muchos informes sobre el rendimiento de los modelos estadísticos y no estadísticos de previsión de las tareas. Un gran número de factores que incluyen los modelos de estructura y datos de la muestra puede afectar a la capacidad de los modelos para predecir la temperatura interior de edificios. Para algunos casos en que la RNA se desempeñó peor que los modelos estadísticos lineales, la razón puede ser simplemente que los datos son lineales, sin mucha perturbación.

Varios trabajos han centrado su investigación hacia la comparación de los métodos estadísticos y no estadísticos. Jiménez (2008) compara una variedad de modelos estocásticos ampliamente utilizados en sistemas lineales. Yiu (2007) estudió el rendimiento del modelo en comparación con un modelo SISO ARMAX. Sinha (2001) presentó un modelo ARX, el razonamiento del modelo se propuso, la cual se modificó para incluir un

método de promedio móvil, como una herramienta eficaz para las predicciones de estos datos. Ríos (2007), demostró que los modelos ARX presentan mejor predicción de la temperatura interna de un edificio de salones de clase comparada con los modelos ARMAX. Mechaqrane y Zouak (2004) mostraron que el modelo NNARX supera considerablemente el modelo lineal: la suma de los cuadrados de error (SSE) fue 15,0479 con el modelo ARX y 2,0632 con el modelo NNARX.

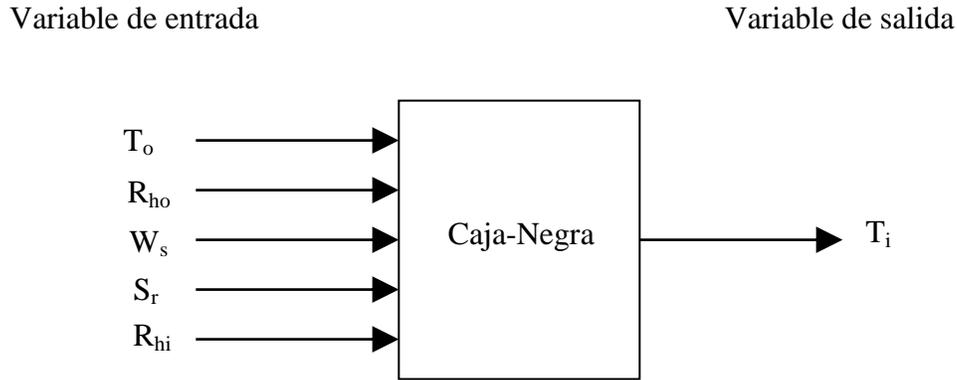
Thomas (2007) implemento modelos de predicción del clima interior en los edificios. Los cuales abarco experimentos de identificación que se llevaron a cabo en dos edificios y los diferentes modelos, como lineales ARX, ARMAX y modelos BJ, así como modelos de RNA no lineales de diferentes órdenes.

Hippert (2000) presentó un sistema híbrido basado en un modelo ARMAX, que produjo mejores resultados que el basado en modelos autorregresivos. Soleimani (2006) mostro que los modelos RNA no-lineal dan las mejores estimaciones que los modelos ARX lineales; los modelos de estimación más precisa se obtuvieron con alimentación hacia adelante, los modelos RNA con una capa oculta de neuronas y el uso de algoritmos de formación.

### **2.3. Estructura del modelo ARX**

Los ARX son modelos matemáticos dinámicos derivados de la teoría de identificación de sistemas, es posible usar modelos dinámicos empíricos para estudiar la temperatura y en general para el clima interior de un edificio (Sargent, 2001; Hontoria et al., 2006). La técnica de construcción de modelos de un sistema dinámico a partir de mediciones se llama identificación de sistemas (Adeloyea et al., 2006).

Un modelo matemático de caja negra describe las relaciones entre las variables de medición, llamadas variables de entrada y las variables denominadas de salida del sistema (Figura 2.1).



**Figura 2.1.** Diagrama de bloques usando 5 variables para la predicción interna de la temperatura en salones de clase.

Existen dos diferentes modelos dentro del enfoque de identificación de sistemas: modelos lineales y no lineales como lo son los modelos ARX y RNA (Uchida et al., 2003).

Aunque las características del clima son variables continuas, estas son medidas y registradas en forma discreta, el sistema dinámico del edificio puede ser modelado por medio de relación lineal auto regresivas entre la salida discreta  $y(t)$  y la entrada discreta  $u(t)$ , tal como los modelos auto regresivos con entrada externa (ARX). La ecuación (3) puede usarse para describir un sistema de una entrada-una salida (Ljung, 1999):

$$y(t) + a_1 y(t-1) + \dots + a_{na} y(t-na) = b_1 u(t-nk) + b_2 u(t-nk-1) + \dots + b_{nb} u(t-nk-nb+1) + e(t) \quad (3)$$

Donde:

$y(t)$ : Es la salida del modelo ARX para  $t = t, t-1, \dots, t-na$ .

$u(t)$ : Es la entrada del modelo ARX modelo para.

$t = t-nk, t-nk-1, \dots, t-nk-nb+1$ .

$na$ : Representa el número de los pasos del tiempo de la salida en el pasado.

$nb$ : Es el número de pasos del tiempo de la entrada en el pasado.

$na$  : Es el retardo de entrada de la  $u(t)$  con respecto a la salida  $y(t)$ .

Los valores se obtienen por el procedimiento de estimación mediante la introducción de los coeficientes como parámetros para la determinación del vector que se calcula:

$$y(t, \theta) = G(z, \theta)u(t) + H(z, \theta)e(t) \quad (4)$$

Para eliminar el ruido blanco como un error directo en las ecuaciones, se puede realizar un ajuste de los parámetros de modelo ARX de la siguiente manera:

$$\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_1 \ b_2 \ \dots \ b_{nb}]^T \quad (5)$$

Los modelos ARX para predecir la temperatura interna con mayor precisión requieren más de una entrada, por lo cual se debe ajustar el modelo ARX SISO en un modelo ARX MIMO. Un modelo ARX multivariable con  $nu$  entradas y  $ny$  salidas está dado por:

$$A(q) y(t) = B(q) u(t) + e(t) \quad (6)$$

Donde  $A(q)$  es una matriz de dimensiones  $ny - por - ny$ . Sus elementos son polinomios en el operador de retraso  $q^{-1}$ .

El desarrollo de modelos basados en el balance de masa y temperatura del ambiente en un edificio requiere de tiempo, ya que deben ser calibrados y validados antes de su optimización y control. Los modelos ARX tienen la ventaja de ser generados rápidamente, ya que se obtienen experimentalmente al establecer la relación entrada-salida del sistema mediante técnicas de identificación de parámetros (Boaventura et al., 1997).

A menudo la ecuación de la estructura ARX Ec. (3) es representada de la siguiente forma:

$$V(z) y(t) = W(z) u(t - n_k) + e(t) \quad (7)$$

Donde las matrices  $V(z)$  y  $W(z)$  están dadas por:

$$\begin{aligned} V(z): 1 + a_1 z^{-1} + \dots + a_{n_a} z^{-n_a} \\ W(z): 1 + b_1 z^{-1} + \dots + a_{n_b} z^{-n_b} \end{aligned} \quad (8)$$

El número de entradas es representada por el número de  $n_u$  y el número de las salidas está representada por  $n_y$ , las matrices  $V(z)$  y  $W(z)$  son  $n_y$  por  $n_y$  y  $n_u$  por  $n_u$  de sus respectivas matrices, cada elemento es un polinomio del operador de desplazamiento  $z^{-1}$ .

Las entradas  $a_{ij}(z)$  y  $b_{ij}(z)$  de las matrices  $V(z)$  y  $W(z)$  son expresadas de la siguiente manera:

$$a_{ij}(z) = \delta_{ij} + a_{1_{ij}} z^{-1} + \dots + a_{n_{ij}} z^{-n_{ij}} \quad (9)$$

$$b_{ij}(z) = b_{ij} z^{-n_{k_{ij}}} + \dots + b_{n_{ij}} z^{-n_{k_{ij}} - n_{ij} + 1} \quad (10)$$

Donde  $\delta_{ij}$  representa el símbolo de kronecker.

La estructura ARX tiene un sistema que se puede definir por medio del número de los polos  $n_a$ , el número de ceros  $n_b - 1$  y el tiempo de retardo  $n_k$  y  $z^{-1}$  es el operador de desplazamiento en retroceso.

$$z^{-1} u(t) = u(t-1) \quad (11)$$

Con el operador de desplazamiento hacia atrás  $q^{-i} y(t) = y(t-i)$

En forma matricial:

$$A(q) = \begin{bmatrix} a_{11}(q) & a_{12}(q) & \dots & a_{ny}(q) \\ a_{21}(q) & a_{22}(q) & \dots & a_{2ny}(q) \\ \dots & \dots & \dots & \dots \\ a_{ny1}(q) & a_{ny2}(q) & \dots & a_{nyny}(q) \end{bmatrix} \quad (12)$$

Donde los elementos  $a_{kj}$  son polinomios en el operador retraso  $q^{-1}$ .

$$a_{kj}(q) = \delta_{kj} + a_{kj}^1 q^{-1} + \dots + a_{kj}^{na} q^{-na} \quad (13)$$

Con:  $\delta_{kj} = 1$

La matriz B (q) está formada como A (q) pero tiene dimensiones  $ny - por - nu$

$$B(q) = B_1 + B_2 q^{-1} + \dots + B_{nb} q^{-nb+1}$$

$$B(q) = \begin{bmatrix} b_{11}(q) & b_{12}(q) & \dots & b_{1nu}(q) \\ b_{21}(q) & b_{22}(q) & \dots & b_{2nu}(q) \\ \dots & \dots & \dots & \dots \\ b_{ny1}(q) & b_{ny2}(q) & \dots & b_{nynu}(q) \end{bmatrix} \quad (14)$$

$$b_{kj}(q) = \delta_{kj} q^{-1} + \dots + \delta_{kj} q^{-nk+1,kj} + b_{kj}^1 q^{-nk,kj} + \dots + b_{kj}^{nb,kj} q^{-nk,kj-nb,kj+1} \quad (15)$$

### 2.3.2. Proceso de identificación de un sistema ARX

La construcción de un modelo ARX requiere de los siguientes pasos:

Paso 1. Diseñar el experimento y se decidir cuáles variables son necesarias para construir un modelo caja negra. También es importante definir un tiempo de muestreo adecuado. Un tiempo demasiado pequeño resulta en muchos datos y un tiempo demasiado grande resulta en modelos imprecisos.

Paso 2. Seleccionar el tipo de modelo. Se usa en esta investigación el ARX modelo. Este modelo no es complicado, es fácil para usar y normalmente permite obtener resultados adecuados.

Paso 3. Elegir el criterio de ajuste. Es importante determinar los parámetros  $na$ ,  $nb$  y  $nk$  adecuados para obtener un modelo ARX preciso. Muchos números de pasos del tiempo en el pasado ( $na$  y  $nb$  grandes) mejorarán el ajuste del modelo a los datos. Pero el modelo será más complejo y los resultados con los datos de validación no mejorarán mucho. El tiempo de retardo ( $nk$ ) de la entrada a la salida es también importante para obtener un modelo exacto. Se puede determinar este retardo para determinar la influencia que tienen las entradas sobre las salidas. Para determinar los valores óptimos de  $na$ ,  $nb$  y  $nk$ . Se puede usar el "Error predicción final de Akaike" (FPE) o "el criterio de información de Akaike" (AIC) (Akaike, 1974). Estos criterios buscan por una función de pérdida mínima en combinación con un número de parámetros estimados mínimo.

$$FPE = \frac{1 + \frac{d}{N}}{1 - \frac{d}{n}} * V \quad (16)$$

$$AIC = \log(V) + \frac{2d}{N} \quad (17)$$

Donde:

V=función de pérdida.

d= número de parámetros estimados.

N= número de datos.

Paso 4. Selección de un subconjunto de datos para construir el modelo y otro subconjunto de datos para verificar el modelo. Primero se construye el modelo ARX usando el primer subconjunto, se puede evaluar el modelo ARX con el otro subconjunto para validar si el modelo funciona adecuadamente.

Paso 5. Si el modelo funciona bien se puede usar, sino se tiene que mejorar y empezar de nuevo a el ciclo de identificación del sistema en el paso 1.

## 2.4. Estructura del modelo RNA

Investigaciones recientes basadas en los modelos RNA han demostrado ser una excelente herramienta, la cual está generando cambios conceptuales y la generación de ciencias cognitivas (Krüger y Zannin, 2004; Hwang et al., 2006). Los modelos RNA hoy en día cuentan con un lugar muy importante en el área de investigación para el modelado y la predicción por su óptima habilidad en el auto-aprendizaje y la solución a problemas de mayor grado de complejidad (Neter, 1996).

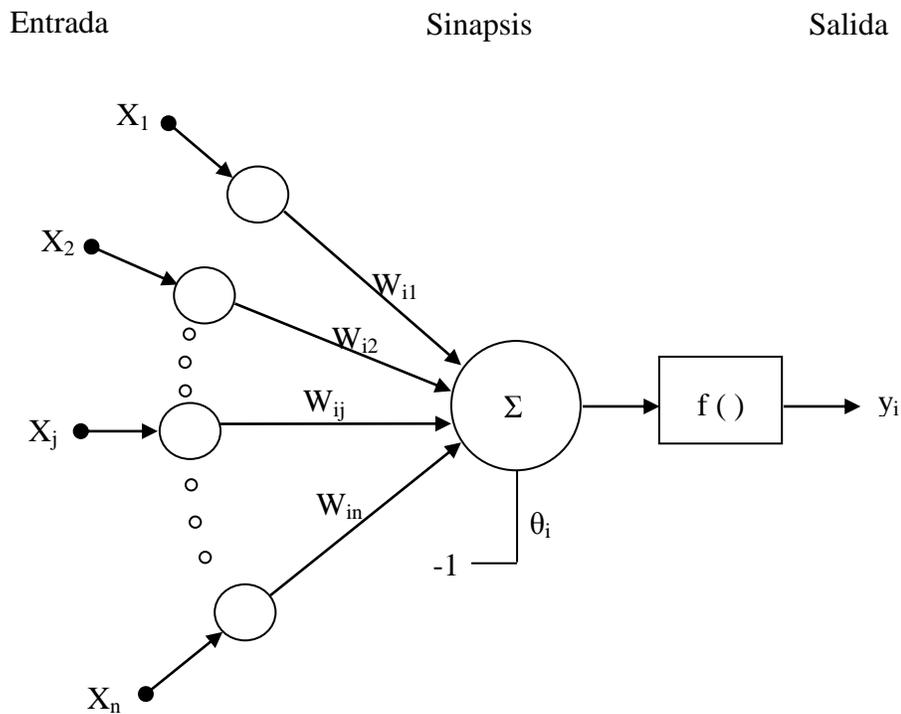
Las redes neuronales artificiales (RNA) son modelos que tratan de replicar de una manera simplificada, el complejo funcionamiento del cerebro humano. Su capacidad de aprendizaje a través de ensayos repetidos, han hecho que sean más útiles por su amplia variedad de aplicaciones en todas las ciencias. Han demostrado ser una herramienta muy útil por su sorprendente habilidad para capturar relaciones no lineales entre variables. De hecho pueden aproximar cualquier función no lineal si son correctamente especificadas (Tkacz y Hu, 1999).

En los últimos años, las RNA han emergido como una tecnología para la modelización y previsión de temperatura debido a su capacidad de aprender las funciones complejas, no lineales. Autorizan a la estimación de modelos no lineales, posiblemente, sin la necesidad de especificar una forma funcional precisa. Las RNA se pueden ver como sistemas paralelo y distribuido de tratamiento que consiste en un gran número de procesadores simples y conectados masivamente llamadas neuronas.

Por arquitectura de una red neuronal artificial se entiende el conjunto de *entradas* incluidas en la parte no lineal,  $p$ , que puede estar completamente contenido en el conjunto de  $k$  variables asociadas a la parte lineal; así como el número de unidades escondidas,  $q$ , y

el número de superficies escondidas, necesarias para la determinación del componente no lineal (Montero et al., 2009).

Una RNA consiste en nodos de entrada, nodos ocultos y nodos de salida, cada uno de estos elementos se encuentra dividido y almacenado en capas, la última capa de salida tiene la característica de contener menos nodos que la de entrada. El funcionamiento de una RNA es por medio de los datos en los nodos de entrada, los cuales se transmiten en toda la red hasta el punto donde se encuentran los nodos de salida (Figura 2.2).



**Figura 2.2.** Modelo de una red neuronal artificial.

Cuando las señales de salida se transmiten a las neuronas de entrada, todas las señales son procesadas de nuevo para realizar el cambio de ponderación neuronal.

Es decir las RNA utilizan un procedimiento para la minimización o maximización de los valores para encontrar los datos más óptimos a través de un número de iteraciones. La ecuación (18) representa la estructura de los modelos RNA.

$$y_t = \alpha_0 + \sum_{j=1}^n \alpha_j f\left(\sum_{i=1}^m \beta_{ij} y_i + \beta_{0j}\right) + \varepsilon_t \quad (18)$$

Donde  $m$  es el número de nodos de entrada,  $n$  es el número de nodos ocultos y  $f$  es la función de transferencia sigmoideal.

Es necesario que los datos sean normalizados para evitar la saturación en los nodos. Si llegase a tener una saturación en los nodos, puede haber pequeñas modificaciones en los valores y provocar errores en el nodo de salida de la red. Por lo cual, los datos deben estar normalizados antes de ser asignados a la red neuronal. La normalización permite comprimir el rango de los valores entre 0 y 1, y se representa de la siguiente manera:

$$X_n = \frac{(x - x_{\min}) * range}{x_{\max} - x_{\min}} + starting\ value \quad (19)$$

Donde  $X_n$  es el valor de los datos normalizados,  $x_{\min}$  es el mínimo y  $x_{\max}$  es el máximo del conjunto de datos.

### 2.4.1 Redes neuronales Feedforward

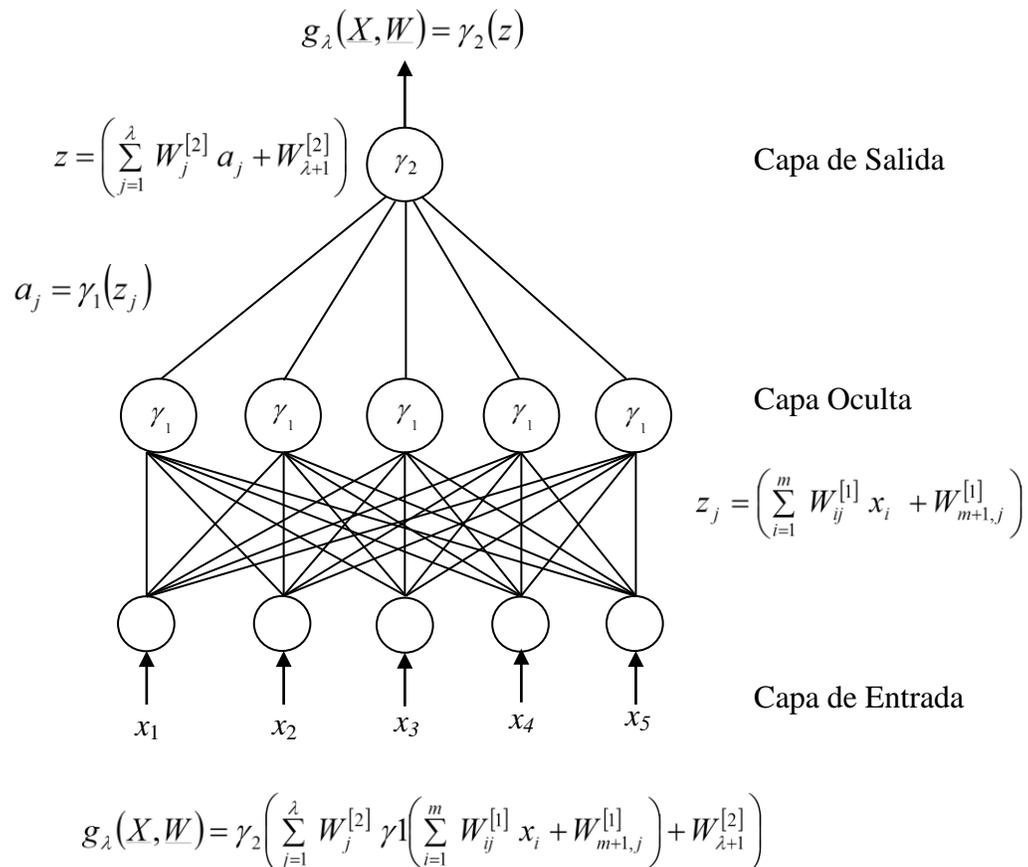
Las redes neuronales feedforward (FANN) corresponde a la clase de RNA más estudiada por el ámbito científico y la más utilizada en los diversos campos de aplicación.

Las diferentes clases de RNA se distinguen entre sí por los siguientes elementos:

- Las neuronas o nodos que constituye el elemento básico de procesamiento.

- La arquitectura de la red descrita por las conexiones ponderadas entre los nodos.
- El algoritmo de entrenamiento, usado para encontrar los parámetros de la red.

Morfológicamente, las FANN consisten en un conjunto de neuronas organizadas en capas (Allende et al., 2002), como se muestra en la Figura 2.3.



**Figura 2.3** Modelo de una red neuronal para el desarrollo de aprendizaje.

Dado un conjunto de observaciones, la tarea del aprendizaje neuronal es construir un estimador  $g_\lambda(x, w)$  de la función desconocida  $h(x)$  del cual se conoce sólo un conjunto de datos.

$$g_{\lambda}(\underline{X}, \underline{W}) = \gamma_2 \left( \sum_{j=1}^{\lambda} W_j^{[2]} \gamma_1 \left( \sum_{i=1}^m W_{ij}^{[1]} x_i + W_{m+1,j}^{[1]} \right) + W_{\lambda+1}^{[2]} \right) \quad (20)$$

Donde  $\underline{w} = (w_1, \dots, w_d)^T$  es el vector paramétrico a ser estimado y equivale a las ponderaciones de las conexiones entre las neuronas de la red,  $\gamma_1$  es una función no-lineal acotada y diferenciable con forma de función sigmoide o de radio basal,  $\gamma_2$  es una función que puede ser lineal o no lineal y  $\lambda$  es el parámetro de control que indica el número de neuronas escondidas.

La función  $\gamma_1$  típicamente es la función sigmoideal dada por:

$$\gamma_1(z) = \frac{1}{1 + e^{-z}} \quad (21)$$

Si la función  $\gamma_2$  se elige no-lineal, debe ser estrictamente monótona, acotada y diferenciable. La función sigmoideal satisface estos requisitos.

Una vez definida la arquitectura que se desea utilizar en un problema particular, la red neuronal debe ajustarse a una muestra dada a través del proceso de aprendizaje. El algoritmo de aprendizaje consiste en un problema de inferencia de los parámetros libres de la red dado por las conexiones entre las neuronas.

El proceso de aprendizaje de una red neuronal feedforward se caracteriza por ser supervisado pues los parámetros de la red, conocidos como pesos, son estimados a partir de un conjunto de patrones de entrenamiento compuesto por patrones de entrada y salida.

Por lo tanto el ajuste de la red se produce como resultado de la estimación de los parámetros basado en una muestra de tamaño  $n$ . La estimación es obtenida minimizando una función de costo es decir:

$$\hat{W}_n = \arg \min \left\{ L_n(w) : w \in \mathcal{W} \subseteq \mathfrak{R}^d \right\} \quad (22)$$

Donde  $L_n(\underline{w})$  normalmente viene dado por la función del promedio de los errores al cuadrado entre el dato estimado por la red y el dato real, es decir:

$$L_n = \frac{1}{2n} \sum_{i=1}^n \left( y_i - g(\underline{x}^i, \underline{w}) \right)^2 \quad (23)$$

De acuerdo a la figura 2.3  $X_1, X_2, \dots, X_n$  representa las entradas de las neuronas;  $W_1, W_2, \dots, W_n$  son los pesos,  $\theta$  es el valor del umbral y  $Y$  representa la salida. La entrada y la salida están relacionadas por:

$$Y(X) = f\left(\sum_{i=1}^n w_i x_i + \theta\right) = f(W^T X + \theta) \quad (24)$$

Donde  $\mathbf{W}$  es el vector de pesos sinápticos,  $\mathbf{X}$  es el vector de entrada y  $\theta$  es una constante llamada sesgo,  $f$  es la función de activación. El superíndice T denota el operador de adaptación y  $\mathbf{Y}(\mathbf{X})$  es la salida de la neurona. Las funciones de activación utilizadas son:

Función logística Sigmoidal:

$$f(x) = [1 + \exp(-x)]^{-1} \quad (25)$$

La función hiperbólica de la tangente (tanh):

$$f(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (26)$$

La función seno ó coseno:

$$\begin{aligned} f(x) &= \sin x \\ f(x) &= \cos x \end{aligned} \tag{27}$$

Función Linear:

$$f(x) = x \tag{28}$$

Cada neurona recibe como entrada un conjunto de señales discretas o continuas, las cuales se pondera e integra, y transmite el resultado a las neuronas conectadas a ella. Cada conexión entre dos neuronas tiene una determinada importancia asociada denominada *peso sináptico* o, simplemente, *peso*. En los pesos se suele guardar la mayor parte del conocimiento que la red neuronal tiene sobre la tarea en cuestión. El proceso mediante el cual se ajustan estos pesos para lograr un determinado objetivo se denomina *aprendizaje o entrenamiento* y el procedimiento concreto utilizado para ello se conoce como *algoritmo de aprendizaje o algoritmo de entrenamiento*. El ajuste de pesos es la principal forma de aprendizaje de las redes neuronales, aunque hay otras formas posibles.

Rumelhart, Hinton y Williams redescubrieron el algoritmo de retropropagación o "backpropagation" como una generalización de la regla delta propuesta por (Widrow y Hoff, 1960). El término de "backpropagation" se refiere a la forma en que el gradiente de la función de costo es calculado para redes neuronales feedforward. El aprendizaje involucra un ajuste de los pesos comparando la salida deseada con la respuesta de la red de manera que el error sea mínimo. La función que usualmente es utilizada para medir el error es la suma de los errores al cuadrado o su promedio. Una de las características más importantes y poderosas de las redes neuronales feedforward es su capacidad como aproximadores universales, esto es, dado cualquier función derivable y acotada, existe una red neuronal con un número suficiente de neuronas escondidas que puede aproximar dicha función con el nivel de precisión deseada.

La demostración de esta propiedad fue desarrollada por (Hornik et al., 1989) a partir de una generalización del teorema de Stone-Weierstrass (Rudin, 1964). En su primera versión (Hornik et. al, 1989), demostraron que las redes neuronales feedforward, en

particular las FANN con 3 capas, y con función de activación de tipo sigmoïdal pueden aproximar cualquier función derivable y acotada con grado de precisión arbitrario para un número suficiente de neuronas escondidas.

Posteriormente White y Stinchcombe (1992) extendieron los resultados obtenidos a las redes feedforward con funciones de activación no-sigmoïdal en la capa escondida.

El modelo propuesto por (McCulloch y Pitts, 1943) fue el primer modelo de red neuronal moderno, y ha sido tomado como punto de partida para el desarrollo de muchos de los modelos neuronales actuales, además de que es utilizado como punto de referencia para evaluar el comportamiento de otros modelos. Sin embargo, en muchos de los estudios en que refieren a este modelo, no se interpreta correctamente el sentido que quisieron dar originalmente McCulloch y Pitts, atribuyéndole características o funciones que no fueron descritas por sus autores y que en realidad no posee, o bien restándole importancia a la capacidad de procesamiento del modelo. Por su parte, el modelo de McCulloch y Pitts por sí mismo está volviendo a tomar importancia debido a que es uno de los pocos modelos digitales y que trabajan en tiempo discreto, a diferencia de la mayoría de los modelos actuales que son modelos analógicos, y debido a que para realizar implantaciones electrónicas o computacionales de las neuronas artificiales en la actualidad se utilizan sistemas digitales, resulta necesario realizar ciertas adaptaciones o aproximaciones numéricas a estos modelos neuronales al momento de implantarlos, lo que dificulta y hace imprecisa su implantación con respecto al comportamiento teórico esperado derivado del modelo.

Las redes neuronales destacan por su estructura fácilmente paralela y por su elevada capacidad de producir salidas correctas para entradas no vistas durante el entrenamiento. Otras propiedades interesantes son:

- *No linealidad.* Una red neuronal puede ser lineal o no lineal. Esta última característica es muy importante, especialmente si se intenta modelizar sistemas generados mediante pautas no lineales.

- *Adaptabilidad.* Las redes neuronales son capaces de reajustar sus pesos para adaptarse a cambios en el entorno. Esto es especialmente útil cuando el entorno que suministra los datos de entrada es *no estacionario*, es decir, algunas de sus propiedades varían con el tiempo.
- *Tolerancia ante fallos.* Una red neuronal es tolerante ante fallos en el sentido de que los posibles fallos operacionales en partes de la red solo afectan débilmente al rendimiento de esta. Esta propiedad es debida a la naturaleza distribuida de la información almacenada o procesada en la red neuronal.

## **2.5 Entrenamiento**

Una vez seleccionado el modelo neuronal con el que resolver un determinado problema, surge la cuestión de cómo determinar el valor de los pesos de la red que permiten resolverlo con éxito. Los algoritmos de entrenamiento se encargan de intentar encontrar esta configuración correcta. En este capítulo se muestran algunos de los más utilizados con RNR, principalmente el descenso por el gradiente y el filtro de Kalman extendido desacoplado. Ambos se basan en el cálculo de la derivada de la función de error; dos son las formas más habituales de obtener estas derivadas: el aprendizaje recurrente en tiempo real y la retropropagación a través del tiempo.

### **2.5.1. Algoritmos de entrenamiento supervisado**

Cuando se desea resolver una determinada tarea con la ayuda de una RNA, lo primero que se debe considerar es el tipo de red que se va a utilizar. La elección no es trivial: hay problemas que se resuelven aceptablemente bien con un tipo de red, pero que son muy difíciles (o imposibles) de resolver con otro.

El número de entradas y de neuronas de salida vienen determinados por la naturaleza de la tarea a resolver, por el tipo de secuencias a procesar o por la codificación utilizada para sus elementos. Otros valores como el número de neuronas de estado o el

orden de entrada o salida deberán ser determinados tras experimentar con distintas combinaciones o usar los límites dados en la teoría para algunos tipos de tarea.

- *Entrenamiento supervisado.* En este tipo de algoritmos la red neuronal cuenta con el apoyo externo de un “maestro” que informa de la corrección de la salida producida por la red de acuerdo con la salida considerada correcta.
- *Entrenamiento no supervisado.* En este caso no existe tal maestro y la red neuronal debe extraer sin ayuda características de los datos que se le suministra.

Para entrenar las redes neuronales artificiales de forma supervisada se necesita normalmente algún tipo de *medida del error*  $E[t]$  que describa la adecuación de la salida proporcionada por la red al valor deseado. Los parámetros se ajustan intentando minimizar este error.

La función de error más habitual es la función de error cuadrático, definida para el instante  $t$  como:

$$E[t] = \frac{1}{2} \sum_{i=1}^{nY} (di[t] - y_i[t])^2 \quad (29)$$

Donde  $di[t]$  es la *salida deseada u objetivo* para la  $i$ -ésima neurona de salida en el instante  $t$  y  $vi[t]$  es la salida correspondiente de la red.

Una posible forma de encontrar la solución que minimice el valor del error es la búsqueda exhaustiva sobre todas las posibles combinaciones de valores de los pesos (o sobre un conjunto finito lo suficientemente significativo de posibles valores). Evidentemente, esta forma de resolución es intratable en la mayoría de los casos. Si el problema a aprender es sencillo, puede que una estrategia basada en generar aleatoriamente conjuntos de valores para los pesos funcione (Hochreiter y Schmidhuber, 1996). En general; sin embargo, se hace necesaria la utilización de algún tipo de heurística que recorte el espacio de soluciones a explorar; esta es la labor de los algoritmos de entrenamiento.



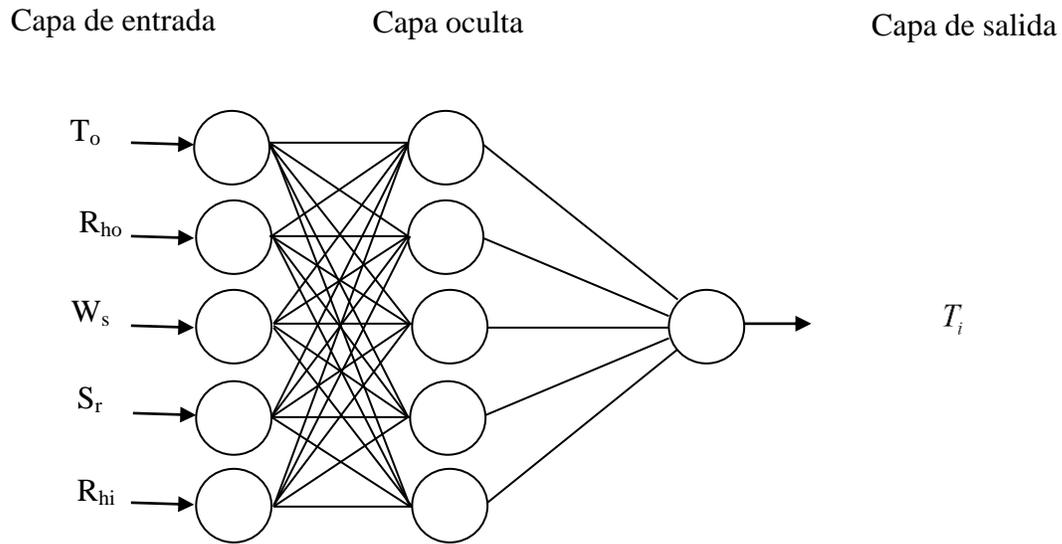
### 2.5.2 Aprendizaje en línea y fuera de línea

Supongamos una red neuronal que se está utilizando para el procesamiento de secuencias. Si la red se aplica a la clasificación de secuencias, por ejemplo, el conjunto de entrenamiento contendrá una serie de secuencias cuya clasificación es conocida de antemano. El algoritmo de entrenamiento debe conseguir que la red “aprenda” estas clasificaciones. Otras veces puede quererse que la red procese una única secuencia en tiempo real. En algunos casos, la red neuronal se somete a una fase de entrenamiento, tras la cual sus pesos se *congelan*. Durante esta fase a la red se le presentan (normalmente más de una vez) los datos del llamado *conjunto de entrenamiento*. A continuación, esta red neuronal se *evalúa* sobre un nuevo conjunto de datos para determinar la corrección del aprendizaje.

En otros casos, las fases de entrenamiento y evaluación no están tan claramente separadas y la salida de la red se usa simultáneamente como punto de referencia para cambiar los pesos y como producto utilizado en la resolución de la tarea en cuestión; cada tipo de procesamiento requiere una estrategia de aprendizaje distinta.

Según la forma de actualizar los parámetros libres (pesos y sesgos, normalmente) de la red neuronal, los algoritmos de entrenamiento supervisado pueden dividirse en las siguientes cuatro clases:

El modelo de una red neuronal se determina por 3 factores: 1) la topología de la red neuronal; 2) las características de los nodos y 3) el entrenamiento de la neurona. La RNA implementada en este estudio son un perceptrón multicapa (MLP), la cual consta de una capa de entrada de 5 nodos, una capa oculta con un número de variables de nodos ocultos y una capa de salida la cual contiene un solo nodo. Las variables de entrada a la RNA son: la temperatura externa, humedad externa, velocidad del viento, radiación solar y humedad interna (Figura 2.4).



**Figura 2.4.** Red neuronal artificial aplicada a 5 variables para la predicción de la temperatura interna.

Para el desarrollo de una red optimizada es necesario la aplicación de varias iteraciones, aun para la solución a problemas menos complejo, para generar una reducción del número de iteraciones y un tiempo mínimo en el aprendizaje de la RNA se pueden aplicar mejoras en el algoritmo de retro propagación, estas pueden ser el descenso del gradiente y el uso del algoritmo de Levenberg-Marquardt (Ríos et al., 2009; Trejo et al., 2009).

## CAPÍTULO III

### 3. Metodología

#### 3.1. Localización del sitio experimental

Se llevó a cabo en las instalaciones de la Facultad de Ingeniería en la Universidad Autónoma de Querétaro, ubicado entre las coordenadas  $20^{\circ} 35' 29.71''$  N y longitud  $-100^{\circ} 24' 38.33''$  O, ubicados específicamente en el área de posgrado (Edificio H) en el cual se realizaron los experimentos (Figura 3.1).

En el estado se encuentran diversos tipos de climas:

- Templados subhúmedos del Sur.- Su temperatura media anual oscila entre  $12^{\circ}\text{C}$  y  $18^{\circ}\text{C}$ . Abarca los municipios de Amealco, Huimilpan y Pedro Escobedo.
- Secos y semisecos del Centro.- Su temperatura media anual oscila entre  $7^{\circ}\text{C}$  y  $25.1^{\circ}\text{C}$ . Abarca los municipios de Querétaro, Corregidora, El Marqués, Ezequiel Montes, Cadereyta, Tequisquiapan, San Juan del Río, Colón, Peñamiller y Tolimán.
- Cálidos y semicálidos del Norte.- Su temperatura media anual oscila entre  $14^{\circ}\text{C}$  y  $28^{\circ}\text{C}$ . Abarca los municipios de Arroyo Seco, Jalpan de Serra, Pinal de Amoles, Landa de Matamoros y San Joaquín (INEGI, 2011).



**Figura 3.1.** Localización del sitio de estudio, Edificio H de posgrado de la facultad de Ingeniería de la Universidad Autónoma de Querétaro.

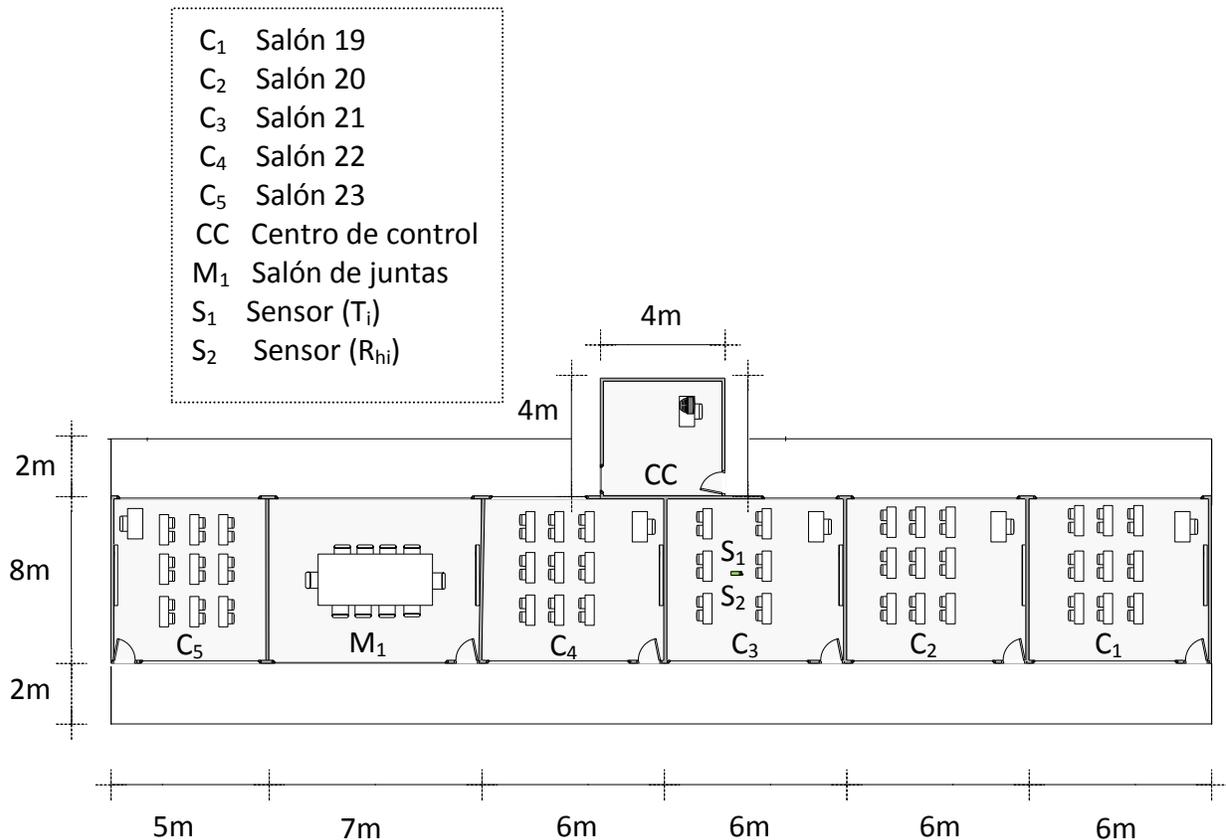
### 3.2 Mediciones de campo

El edificio donde se desarrolló la investigación cuenta con las siguientes características estructurales; tiene 12 cm de una gruesa capa de concreto en la parte superior. La capa de concreto tiene una resistencia de 300 kg/cm<sup>2</sup>. Las paredes laterales están construidas con 14 cm de espesor x30cm de ladrillos. El diseño incluye dos de 4 m de largo x 2 m de altura, ventanas en el lado norte y una en el lado sur. Los muros dividen los salones que están hechos de bloques de concreto revestido con mortero, con acabados interiores y exteriores. Cuenta con 0,5 mm y 0,7 cm de espesor de pintura de vinil. La parte superior está cubierta por una capa a prueba de agua Protexa y arena roja (Figura 3.2).



**Figura 3.2.** Estructura del salón de clase (Vista desde el lado sur).

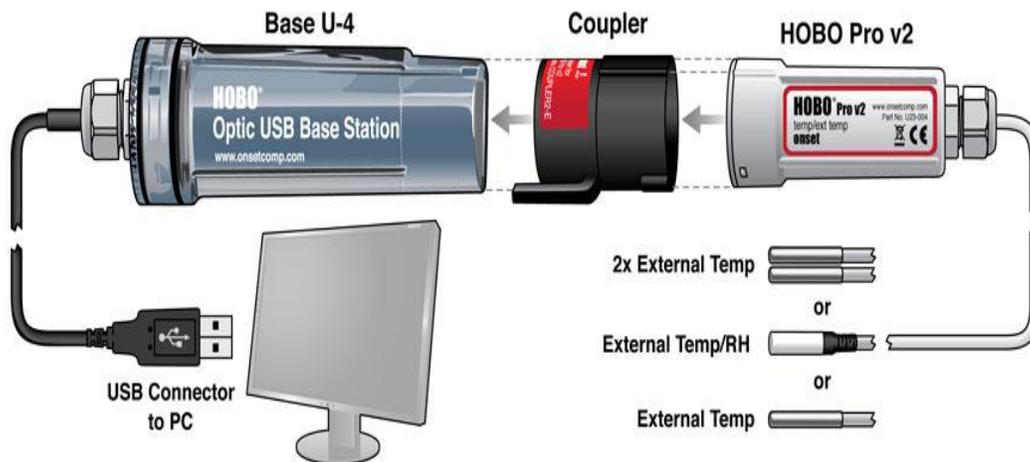
Cuenta con 5 salones de clase, un salón de juntas y un cuarto de control; cubriendo un total de 304 m<sup>2</sup>. La altura de la estructura es de 3m. El uso de los salones es de manera independiente, sin embargo estos se utilizan simultáneamente la mayor parte del tiempo. Los salones de clase para este estudio pueden considerarse como idénticos (Figura 3.3).



**Figura 3.3.** Vista del edificio (dimensiones en metros).

La edificación tiene implementado un sistema digital de ahorro y análisis de consumo y calidad de la energía eléctrica para edificios inteligentes con el nombre de MONITO-UAQ (Trejo et al., 2005).

Se empleó un sensor data logger HOBO el cual registra los datos de temperatura ( $T_i$ ) y humedad ( $R_{hi}$ ) serie pro V2, es un equipo apto para interiores que cuenta con una memoria de 64Kb, una resolución de 12 bits, inicios de intervalos de muestreo que van desde 1 segundo hasta 18 horas, teniendo una capacidad de almacenamiento de hasta 42000 datos de muestreo, dimensiones de 102x38 mm., con una interfaz óptica con conexión USB, ver Figura 3.4.



**Figura 3.4.** Diseño del sensor de monitoreo de temperatura y humedad.

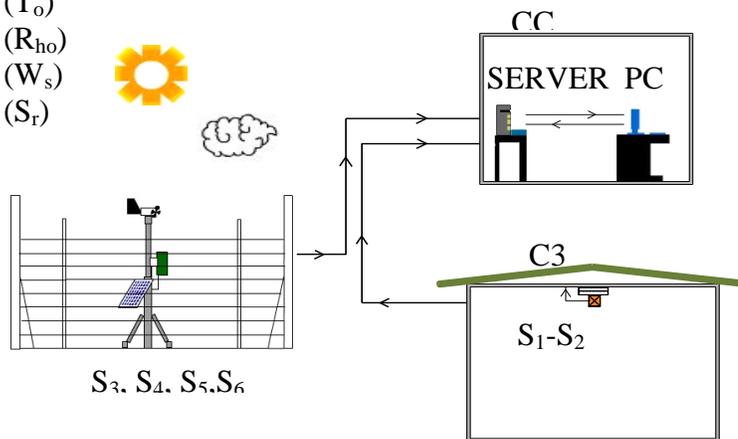
Las características con las que cuenta el data logger HOBO pro V2 son las mediciones de la temperatura con un tiempo de muestra el cual puede ser configurable, además de contar con un software que permite la descarga de los datos en formato .xls, los rangos en que opera el sensor se muestran en la Tabla 3.1.

Tabla 3.1. Rangos de operación del data logger HOBO pro V2.

| Rangos            |                         |
|-------------------|-------------------------|
| Temperatura:      | -40° a +70°C            |
| Precisión:        | ± 0.2°C entre 0° y 50°C |
| Resolución:       | 0.02°C a 25°C           |
| Humedad relativa: | 0 a 100%                |
| Precisión:        | ± 2.5% entre 10 y 90%   |
| Resolución:       | 0.03%                   |

Para medir las variables climáticas al interior del salón C<sub>3</sub>, un sensor registrador de temperatura (T<sub>i</sub>) y humedad relativa (R<sub>hi</sub>) marca HOBO Pro V2 fue instalado a una altura de 2.9 m respecto al suelo. Para la comunicación del sensor registrador con la computadora se utilizó una base estación óptica universal. Los datos climáticos externos fueron proporcionados por la base de datos de la estación meteorológica IQUERETA3 de la Comisión Estatal del Aguas del estado de Querétaro (CEA-2011). De la estación meteorológica IQUERETA3 se utilizaron los datos de temperatura externa °C, humedad externa (%), velocidad del viento (m/s), radiación solar (W/m<sup>2</sup>), la hora y el día (Figura 3.5).

- CC Control center
- C<sub>3</sub> Classroom 21
- S<sub>1</sub> Sensor (T<sub>i</sub>)
- S<sub>2</sub> Sensor (R<sub>hi</sub>)
- S<sub>3</sub> Sensor (T<sub>o</sub>)
- S<sub>4</sub> Sensor (R<sub>ho</sub>)
- S<sub>5</sub> Sensor (W<sub>s</sub>)
- S<sub>6</sub> Sensor (S<sub>r</sub>)



**Figura 3.5.** Diseño de comunicación entre CEA y HOBO Pro V2. (Vista lateral derecha).

Con el fin de poder obtener los coeficientes para los modelos matemáticos ARX y RNA, las medidas de las variables se realizaron mediante un muestreo cada 10 minutos durante un período de 365 días para predecir la temperatura interna en las aulas del edificio. Estos datos se dividieron en 4 grupos, que conforman las 4 estaciones del año; de las cuales, se utilizaron para el desarrollo de esta investigación solo 2 estaciones del año, la de verano e invierno; por ser estas donde mayores cambios climáticos se presentaban.

Esta investigación se basa en el análisis de las variables de entrada, que son: ( $T_o$ ,  $R_{ho}$ ,  $W_s$ ,  $S_r$ ,  $R_{hi}$ ), siendo la temperatura interna la variable de salida ( $T_i$ ); los datos medidos fueron utilizados para obtener los coeficientes de los modelos.

### **3.3 Medidas de Precisión**

Los valores de entrada y salida que se registran durante el desarrollo del experimento de identificación, en los cuales se determinan las señales de entrada, así como las debidas restricciones que se deben considerar. Teniendo un conjunto de modelos ARX y RNA candidatos, obteniéndose mediante su especificación para seleccionar cuidadosamente los modelos más adecuados de las temporadas de verano e invierno y así hacer una comparación de las capacidades de predicción de la temperatura interna entre los datos reales, los del modelos ARX y los de RNA.

Para los modelos ARX de acuerdo con (Ljung, 1999) una vez que los datos han sido registrados, los dos primeros tercios del registro de datos se utilizaron para determinar los coeficientes del modelo y el resto de los datos para su validación.

El algoritmo de las RNA empleado para la predicción de la temperatura interna del edificio se acoplo al algoritmo de Levenberg-Marquardt. El mejor promedio es seleccionado de las diferencias absolutas entre los valores medidos y estimados; expresados como porcentaje de los valores medidos desde su resultado como un porcentaje.

Los mejores modelos ARX son comparados con los mejores modelos de las RNA correspondientes a las estaciones de verano e invierno; utilizando como base el coeficiente de determinación ( $R^2$ ) (Neter et al., 1996), el cual es una medida de correlación entre el dato medido y el estimado, algunas medidas de variación como el standard error prediction (*SEP*) (Ventura et al., 1995) , mean square error (*MSE*) (Neter et al., 1996) y mean absolute percent error (*MAPE*) (Griño,1992), para comparar los resultados y poder determinar la capacidad de de los modelos y la varianza total de datos. La ecuación de MAPE para cada modelo se calcula de la siguiente manera:

$$MAPE = \frac{1}{N} \sum_{j=1}^N \frac{|Ue_j - Ua_j|}{Ua_j} \quad (30)$$

Donde  $Ue_j$  es la predicción de la temperatura estimada,  $Ua_j$  es la predicción de la temperatura medida y N es el número total de muestras realizadas.  $R^2$ , SEP y MSE se determinan de acuerdo a las Ecuaciones (30 y 32) respectivamente.

$$R^2 = 1 - \frac{SSE}{SSTO}; \quad SSE = \sum (Ua_j - Ue_j)^2; \quad SSTO = \sum (Ua_j - \bar{Ua}_j)^2 \quad (31)$$

Donde SSTO es una medida de variabilidad de los datos observados, SSE es una medida de relación entre los valores de predicción y los valores medidos. El SEP se define de acuerdo a la ecuación (32):

$$SEP = \frac{1}{Ua_j} \sqrt{\frac{\sum_{j=1}^N (Ue_j - Ua_j)^2}{N}} \quad (32)$$

y el MSE se define de acuerdo a la ecuación. (33):

$$MSE = \frac{\sum (Ua_j - Ue_j)^2}{N - 2} \quad (33)$$

Donde  $N-2$  corresponde a los grados de libertad.

Con esta arquitectura de red se considera el mejor promedio, seleccionado de las diferencias absolutas entre los valores medidos y los valores estimados, expresados en porcentaje de los valores medidos desde su resultado, el cual no depende de la magnitud de los datos de entrada. El objetivo de las RNA es encontrar una configuración óptima de pesos, de modo que puedan aprender un conjunto de patrones, por lo cual se convierte en un problema de programación lineal; para ello el algoritmo se describe de la siguiente manera:

- Determinar las variables de entradas y salidas del modelo.
- Se agrupan las entradas y las salidas que se encuentran relacionadas.
- Los datos se divide en dos partes: una parte se utiliza para el entrenamiento y así encontrar la determinación de los parámetros de la red neuronal y la otra parte de datos, llamada de prueba se utiliza para estimar el error. El entrenamiento se divide en un subconjunto de validación para ajustar el modelo.
- La relación entre las entradas y salidas de la red neuronal se estima. Estos pasos se repiten para encontrar el número adecuado de nodos ocultos, utilizando diferentes parámetros de formación para la red; 80% de los datos se utilizan para entrenar la red, 10% para la validación y el último 10% para estimar la generalización.

## CAPÍTULO IV

### 4. Resultados y discusión

#### 4.1. Selección de los modelos

Se desarrollaron y probaron varios modelos ARX y RNA todo esto de acuerdo a la capacidad de predicción de la temperatura interna. Los datos fueron divididos en 4 grupos de acuerdo a las estaciones del año; utilizando solo las estaciones de verano e invierno para el desarrollo de esta investigación. El MAPE se utilizó para comparar la capacidad de predicción de los modelos ARX y RNA con la finalidad de determinar los mejores modelos.

La estructura del modelo y los resultados de los parámetros de identificación para las temporadas, tomando en cuenta las siguientes variables:  $(T_i)$  como la temperatura interna,  $(T_o)$  como la temperatura externa,  $(R_{ho})$  humedad relativa externa,  $(W_s)$  velocidad del viento,  $(S_r)$  flujo de radiación global,  $(R_{hi})$  humedad relativa interna y  $(e)$  es la perturbación en el tiempo  $(t)$ , usando la transformada Z para las operaciones  $(Z^{-1})$ ;  $a_1 - a_5$ ,  $b_{11} - b_{53}$  y  $c_1 - c_5$  son coeficientes de regresión que están definidos en la estructura del modelo, ecuación (34).

$$T_i(t) = \frac{[T_o(t) R_{ho}(t) W_s(t) S_r(t) R_{hi}(t)]}{1 + a_1 z^{-1} + a_2 z^{-2} + a_3 z^{-3} + a_4 z^{-4} + a_5 z^{-5}} \times \begin{bmatrix} b_{11} z^{-1} + & + b_{12} z^{-2} + & b_{13} z^{-3} \\ b_{21} z^{-1} + & b_{22} z^{-2} + & b_{23} z^{-3} \\ b_{31} z^{-1} + & b_{32} z^{-2} + & b_{33} z^{-3} \\ b_{41} z^{-1} + & b_{42} z^{-2} + & b_{43} z^{-3} \\ b_{51} z^{-1} + & b_{52} z^{-2} + & b_{53} z^{-3} \end{bmatrix} \quad (34)$$

$$+ \frac{1 + c_1 z^{-1} + c_2 z^{-2} + c_3 z^{-3} + c_4 z^{-4}}{1 + a_1 z^{-1} + a_2 z^{-2} + a_3 z^{-3} + a_4 z^{-4} + a_5 z^{-5}} e^{(t)}$$

En la Tabla 4.1 se muestran los resultados de los mejores modelos correspondientes al periodo de verano, su confiabilidad y el mejor rendimiento.

El modelo ARX (4,3,0) correspondiente al periodo de verano, fue el mejor comparado con los demás modelos de ARX, obteniendo un  $R^2$  de 0.9830, un MAPE de 0.0337, y un SEP de 0.0397; el modelo RNA (6,4,1) correspondiente al mismo periodo de verano fue el de que obtuvo la mejor estimación de la temperatura interna, con un  $R^2$  de 0.9400, un MAPE de 0.0215y un SEP de 0.0374.

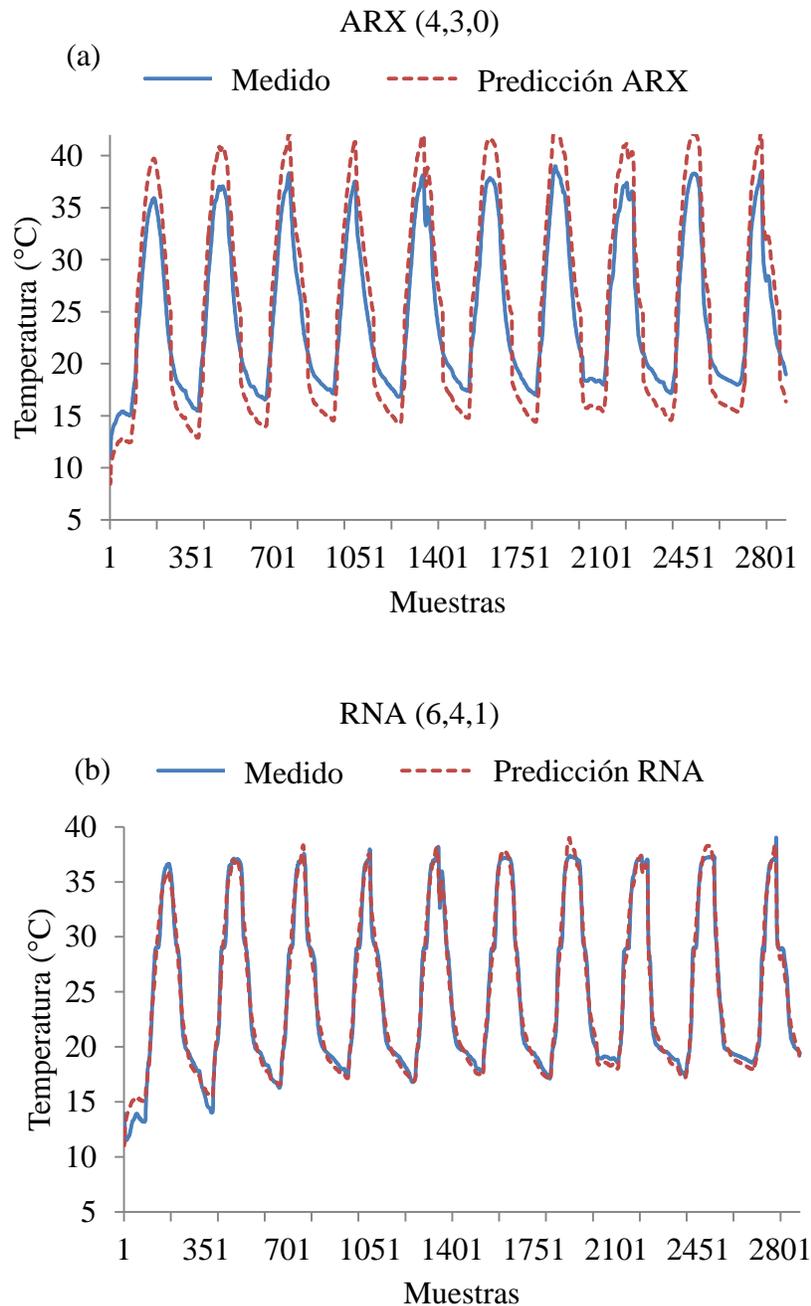
**Tabla 4.1.** Comparación del error estimado de los diferentes modelos ARX y RNA en la temporada de verano.

| Modelo     | Validación |        |        |
|------------|------------|--------|--------|
|            | $R^2$      | MAPE   | SEP    |
| <b>ARX</b> |            |        |        |
| 4,6,0      | 0.9681     | 0.0478 | 0.0541 |
| 4,5,0      | 0.9540     | 0.0556 | 0.0646 |
| 4,4,0      | 0.9726     | 0.0458 | 0.0500 |
| 4,3,0      | 0.9830     | 0.0337 | 0.0397 |
| 4,2,0      | 0.9671     | 0.0414 | 0.0559 |
| <b>RNA</b> |            |        |        |
| 6,6,1      | 0.9412     | 0.0371 | 0.0255 |
| 6,5,1      | 0.9306     | 0.0403 | 0.0315 |
| 6,4,1      | 0.9400     | 0.0374 | 0.0215 |
| 6,3,1      | 0.9359     | 0.0387 | 0.0252 |
| 6,2,1      | 0.9411     | 0.0371 | 0.0279 |

ARX: modelo autoregresivo con entrada externa; RNA: red neuronal artificial.

Comparando los modelos ARX con modelos de las RNA correspondientes a la temporada de verano, se puede observar que los modelos RNA mejora el desempeño de los modelos ARX; obteniendo un MAPE y un SEP por debajo que el modelos ARX. Se consideran 144 muestras equivalentes al comportamiento climático de un día, usadas para la validación del comportamiento de los datos medidos respecto a los datos estimados de

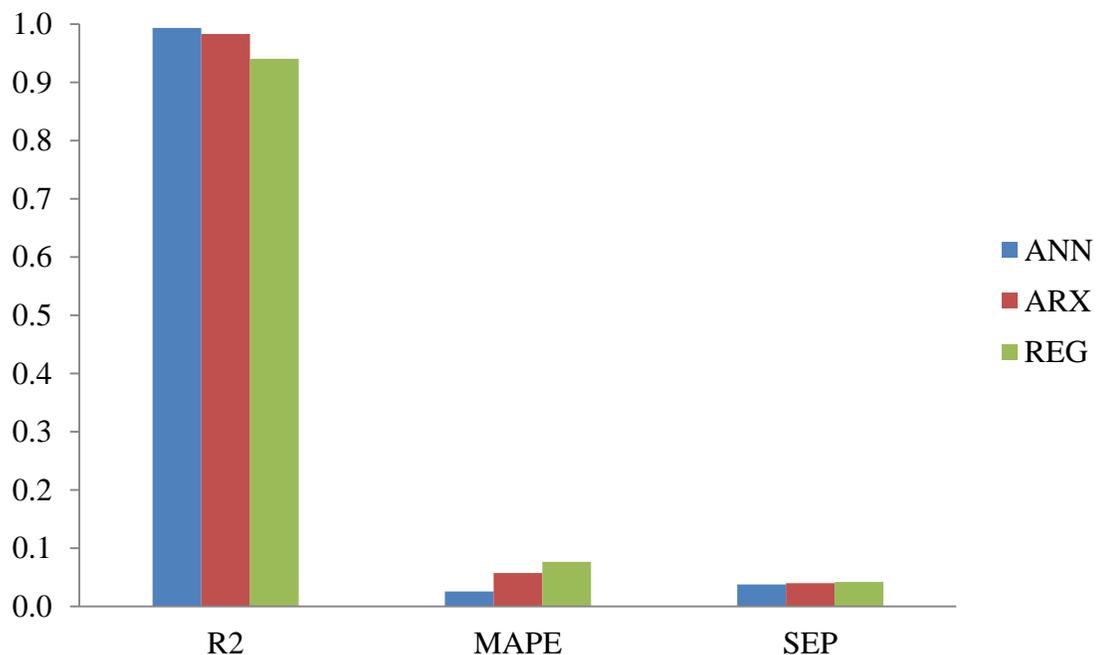
los modelos ARX y RNA, considerando 2880 muestras de las temporadas de verano e invierno, dando un total de 20 días de estimación como se visualiza en la Figuras 4.1 y 4.3 (a y b) correspondientes a la temporada de verano e invierno respectivamente.



**Figura 4.1.** Comparación de los datos originales medidos contra los resultados de (a) los modelos autoregresivos con entrada externa (ARX) y (b) los modelos de redes

neuronales artificiales (RNA) y la diferencia entre las muestras de ambos modelos de la temporada de verano — medidos; - - - predicción.

Se realizó un análisis del desempeño de la estimación de la temperatura y del error de los modelos de la temporada de verano Figura 6 (a y b) en ella se muestra la exactitud de los modelos ARX y la de los modelos RNA en cuanto a la predicción de la temperatura interna del edificio se refiere. Los resultados estimados se comparan con los datos medidos. El modelo ARX (4,3,0) muestra un 3% de error y el modelo RNA (6,4,1) muestra un 1% de error, basándose en los mejores resultados los modelos desarrollados que dieron una mejor predicción de la temperatura interna son los modelos de RNA con respecto a los modelos ARX. La comparación del modelo ARX, el modelo RNA y la regresión de la época de verano, en cuanto al MAPE, MSE y R2, muestran que los modelos de predicción con la RNA tienen un error menor en comparación con los resultados de los modelos ARX y de regresión (Figura 4.2).



**Figura 4.2.** Comparación del error de los modelos ARX, RNA y regresión de la temporada de verano.

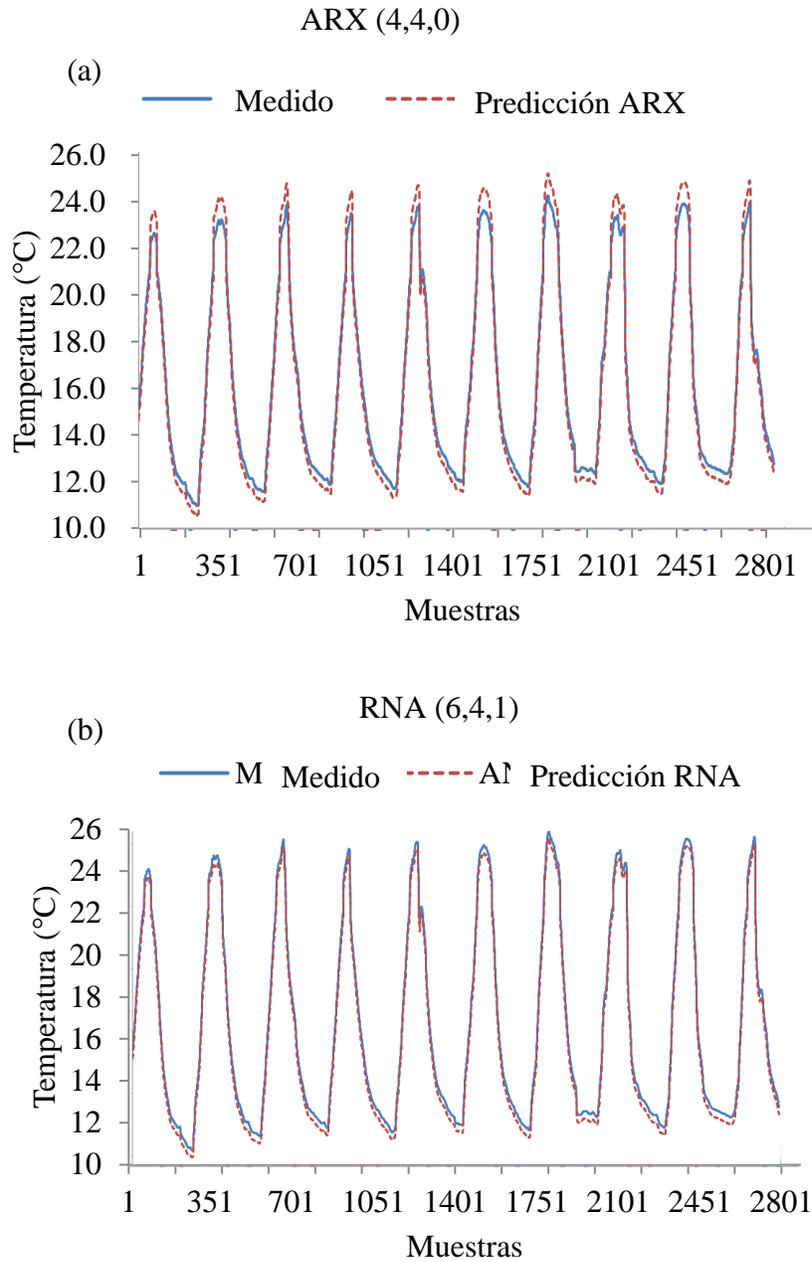
En la Tabla 4.2 se muestran los resultados de los mejores modelos correspondientes al periodo de invierno, su confiabilidad y el mejor rendimiento. El modelo ARX (4,4,0) correspondiente al periodo de invierno, fue el mejor comparado con los demás modelos de ARX, obteniendo un  $R^2$  de 0.9797, un MAPE de 0.0401, y un SEP de 0.0430; por su parte el modelo RNA (6,4,1) correspondiente al mismo periodo de invierno fue el modelo de las RNA que obtuvo la mejor estimación de la temperatura interna, con un  $R^2$  de 0.9647, un MAPE de 0.0565 y un SEP de 0.0609.

**Tabla 4.2.** Comparación del error estimado de los diferentes modelos ARX y RNA en la temporada de invierno.

| Modelo     | Validación |        |        |
|------------|------------|--------|--------|
|            | $R^2$      | MAPE   | SEP    |
| <b>ARX</b> |            |        |        |
| 4,5,0      | 0.9588     | 0.0579 | 0.0510 |
| 4,5,1      | 0.9419     | 0.0707 | 0.0320 |
| 4,4,0      | 0.9797     | 0.0430 | 0.0401 |
| 4,4,1      | 0.9675     | 0.0528 | 0.0300 |
| 4,3,1      | 0.9681     | 0.0526 | 0.0400 |
| <b>RNA</b> |            |        |        |
| 6,6,1      | 0.9585     | 0.0639 | 0.0661 |
| 6,5,1      | 0.9465     | 0.0581 | 0.0751 |
| 6,4,1      | 0.9647     | 0.0565 | 0.0609 |
| 6,3,1      | 0.9325     | 0.0821 | 0.0843 |
| 6,2,1      | 0.9233     | 0.0870 | 0.0898 |

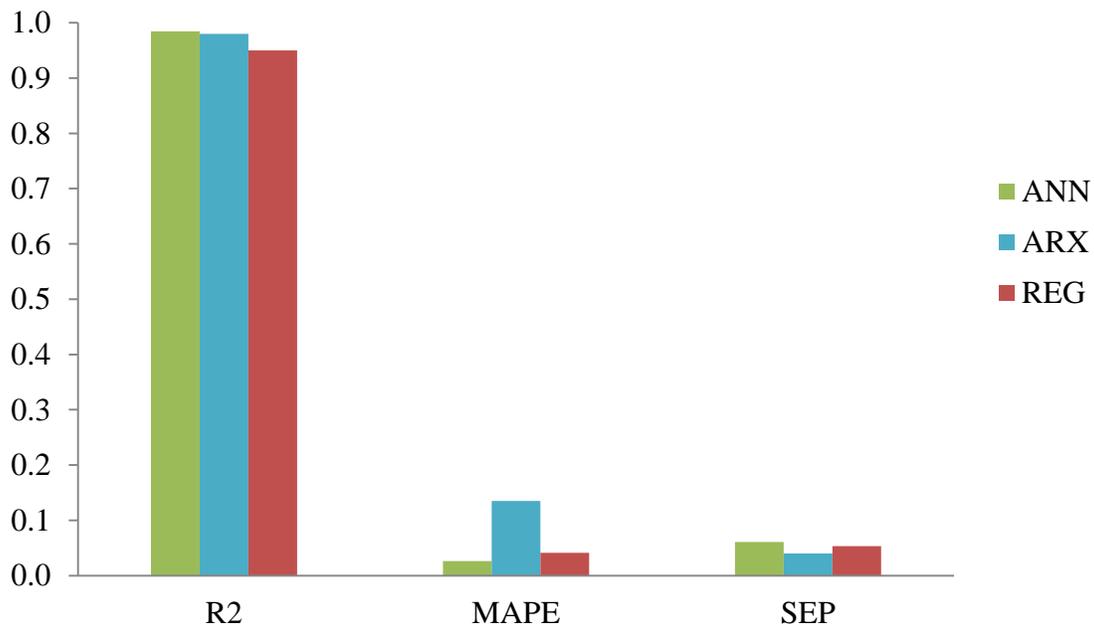
ARX: modelo autoregresivo con entrada externa; RNA: red neuronal artificial.

Comparando los modelos ARX con los modelos de las RNA de la temporada de invierno, se puede observar que los modelos RNA mejora nuevamente el desempeño de los modelos ARX; obteniendo un MAPE y un SEP por debajo que el modelos ARX.



**Figura 4.3.** Comparación de los datos originales medidos contra los resultados de (a) los modelos autoregresivos con entrada externa (ARX) y (b) los modelos de redes neuronales artificiales (RNA) y la diferencia entre las muestras de ambos modelos de la temporada de invierno — medidos; - - - predicción.

En la Figura 4.4 se puede observar la comparación entre los datos medidos y los datos estimados de los mejores modelos ARX y RNA de la temporada de invierno. Los resultados muestran que el modelo ARX (4,4,0) genero un error del 6% mientras que el modelo RNA (6,4,1) tuvo un error del 1.3 %, basándose en los mejores resultados los modelos desarrollados que dieron una mejor predicción de la temperatura interna son nuevamente los modelos de RNA con respecto a los modelos ARX. La comparación del modelo ARX, el modelo RNA y la regresión de la época de invierno, en cuanto al MAPE, MSE y  $R^2$ , muestran nuevamente que en esta temporada los modelos de predicción con la RNA tiene un error menor en comparación con los resultados de los modelos ARX y de regresión (Figura 4.4).



**Figura 4.4.** Comparación del error de los modelos ARX, RNA y regresión de la temporada de invierno.

Tomando los valores estimados de los modelos RNA, ARX y de regresión lineal de la temporada de verano e invierno con los datos medidos, comparados mediante el análisis de varianza (ANOVA) (Trejo et al., 2005), fue utilizado para comparar los errores sistemáticos con los aleatorios que se obtuvieron al realizar el análisis con los distintos valores medios para así determinar si alguno de ellos difiere significativamente (Tablas 4.3 y 4.4).

**Tabla 4.3.** Comparación mediante ANOVA de los datos medidos contra los datos comparados de los modelos ARX y RNA de la temporada de verano.

| Grupos       | Conteo     |        |            | Suma    | Promedio     |               |
|--------------|------------|--------|------------|---------|--------------|---------------|
| Medidos      | 101        |        |            | 2896.11 | 28.67        |               |
| ARX          | 101        |        |            | 2789.75 | 23.62        |               |
| RNA          | 101        |        |            | 2884.41 | 28.56        |               |
|              | Suma       |        |            |         |              |               |
| Fuente       | Cuadrática | Grados | Cuadrático | F       | F0.01(3,299) | F0.025(3,299) |
| Entre Grupos | 67.37      | 3      | 22.46      | 0.04    | 4.69         | 3.17          |
| Bloques      | 41.27      | 100    | 0.41       |         |              |               |
| Sin Grupos   | 146068.86  | 299    | 486.90     |         |              |               |
| Total        | 146177.50  |        |            |         |              |               |

Al realizar el análisis de varianza de los 3 grupos a comparar (datos medidos, ARX y RNA) de la temporada de verano se logró la obtención de un promedio de mayor aproximación los modelos RNA entre los datos medidos el cual es mínima la diferencia que hay en estos dos grupos dando como resultado a los modelos de predicción RNA tienen mayor efectividad para la estimación de temperatura que los modelos ARX Tabla 4.3.

**Tabla 4.4.** Comparación mediante ANOVA de los datos medidos contra los datos comparados de los modelos ARX y RNA de la temporada de invierno.

| Grupos       | Conteo     |        |            | Suma    | Promedio     |               |
|--------------|------------|--------|------------|---------|--------------|---------------|
| Medidos      | 101        |        |            | 1381.11 | 13.67        |               |
| ARX          | 101        |        |            | 1537.78 | 17.22        |               |
| RNA          | 101        |        |            | 1369.44 | 13.55        |               |
|              | Suma       |        |            |         |              |               |
| Fuente       | Cuadrática | Grados | Cuadrático | F       | F0.01(3,299) | F0.025(3,299) |
| Entre Grupos | 174.97     | 3      | 58.32      | 0.46    | 3.86         | 3.16          |
| Bloques      | 41.27      | 100    | 0.41       |         |              |               |
| Sin Grupos   | 37411.20   | 299    | 124.70     |         |              |               |
| Total        | 37627.44   |        |            |         |              |               |

Desarrollando un segundo análisis de varianza para la temporada de invierno para los grupos (RNA, ARX y datos medidos), obteniendo una mayor efectividad de promedios entre los modelos RNA y los datos medidos con una mínima diferencia de aproximación, dando como conclusión que los modelos RNA superan a los ARX aun cuando los ARX dan una buena estimación de la temperatura interna Tabla 4.4.

Se realizaron proposiciones sobre los valores determinados en los modelos para tomar una decisión entre aceptarlos o rechazarlos mediante una herramienta de análisis de datos llamada prueba de hipótesis.

$$H_0: \mu = \mu_0 = \mu_1 \quad H_1: \mu \neq \mu_0$$

Con el fin de encontrar cuales medias de los tratamientos de regresión, ARX y RNA están más cerca de los datos reales, se aplica la prueba de rango múltiple de Duncan (DMRT). Para realizar esta prueba, encontramos la desviación estándar de cada media de los tratamientos, de la siguiente manera:

$$S_x = \sqrt{\frac{MS(error)}{n_j}} \quad (35)$$

Donde  $n_j$  es el número de réplicas de observación para los tres tratamientos (medición de la temperatura, ARX y RNA). Entonces, los valores de estado  $R_p$  se calculan como:

$$R_p = ra(p, f) S_x \quad (36)$$

$R_p$  se entiende como la diferencia mínima que debe existir entre el valor más grande y el valor más pequeño del conjunto de datos medidos;  $ra(p, f)$  se obtiene de la tabla Duncan. Después de haber generado un tratamiento de clasificación, cada tratamiento puede ser comparado de la siguiente manera:

Después de la clasificación de la media de tratamiento, podemos comparar cada tratamiento de la siguiente manera (Tabla 4.5).

**Tabla 4.5.** Comparación de la media de los tratamientos 1,2 y 1,3.

| Temporada       |                                      |                                   |                      |
|-----------------|--------------------------------------|-----------------------------------|----------------------|
| <b>Verano</b>   | $S\bar{x}$                           | $r_{0.05} (3,299)$                | $r_{0.05} (100,299)$ |
|                 | 2.20                                 | 4.62                              | 2.85                 |
|                 | Comparación de tratamientos 1 y 2    | Comparación de tratamientos 1 y 3 |                      |
|                 | 22.59-20.23 =2.35 $\mu 1 \neq \mu 2$ | 22.59-15.58=7.01                  | $\mu 1 = \mu 3$      |
| <b>Invierno</b> | $S\bar{x}$                           | $r_{0.05} (3,299)$                | $r_{0.05} (100,299)$ |
|                 | 1.11                                 | 2.93                              | 1.45                 |
|                 | Comparación de tratamientos 1 y 2    | Comparación de tratamientos 1 y 3 |                      |
|                 | 22.13-20.79 =1.34 $\mu 1 \neq \mu 2$ | 22.13-15.22=6.91                  | $\mu 1 = \mu 3$      |

Aceptando la hipótesis nula al comparar el modelo de red neuronal con los datos medidos, con un  $\alpha=0.05$  en la prueba, obteniendo un 95% de confiabilidad; lo anterior indica que la temperatura interna estimada para los valores seleccionados de los modelos RNA de verano e invierno con los datos medidos de cada época son significativamente iguales.

## 4.2. Conclusiones

Se presenta un procedimiento para la obtención de modelos lineales autoregresivos con entrada externa dinámico (ARX) y redes neuronales artificiales (RNA), los cuales nos permite una predicción del comportamiento de la temperatura del aire en el interior en un salón de clase. Temperatura externa, humedad relativa externa, velocidad del viento, radiación solar y humedad relativa interna son las variables de entrada utilizadas y la temperatura interna como variable de salida. Se muestrearon las variables climáticas externa de la estación meteorológica IQUERETA3 proporcionadas por la CEA, se dividieron en 2 secciones correspondientes a las temporadas de verano e invierno para la evaluación y desarrollo de los modelos ARX y RNA. Los resultados evaluados en el conjunto de datos tomados de la temporada de verano para estimar y validar los modelos ARX tomando en consideración que el modelo ARX (4,3,0) fue el mejor modelo dando un  $R^2$  de 0.9830, un MAPE de 0.0337y un SEP de 0.0397, así también se evaluó la temporada de invierno siendo el mejor modelo el ARX (4,4,0) con un  $R^2$  de 0.9797, un MAPE de 0.0401y un SEP de 0.043. Estos dos modelos se utilizaron para compararlos con los modelos RNA.

Un método muy eficaz para la predicción de la temperatura es el uso de modelos de RNA el cual se puso a prueba. El predictor de temperatura interna utilizo un algoritmo de Levenberg-Marquardt para el mejoramiento del modelo. La construcción del modelo de verano RNA (6,4,1) fue capaz de producir los mejores resultados en la predicción de la temperatura interna en el edificio, con un  $R^2$  de 0.9400, un MAPE de 0.0215y un SEP de 0.0374; para la época de invierno el modelo RNA (6,4,1) obtuvo un  $R^2$  de 0.9647, un MAPE de 0.0565, y un SEP de 0.0609; mejorando la actuación de los modelos ARX en ambas estaciones del año.

Se utilizó el método estadístico ANOVA para estimación de la variación de las 2 temporadas, comparando los resultados de los modelos ARX con los resultados de los modelos de RNA en comparación con los datos medidos; obteniendo los modelos RNA un 95 % de confiabilidad en la estimación de la temperatura, encontrando que los modelos

RNA son más cercanos a los datos medidos para la predicción de la temperatura interna del edificio superando significativamente a los modelos ARX aun cuando los modelos ARX dan una buena estimación de la temperatura interna.

Los modelos desarrollados en la época de verano e invierno dieron un acercamiento de los datos medidos de la predicción de la temperatura. El desarrollo y enfoque de esta investigación podría utilizarse para diseñar una estrategia de control inteligente de la predicción de la temperatura interna en edificios inteligentes.

## **Bibliografía**

- Adeloyea, A.J., and De Munarib, A. 2006. Artificial neural network based generalized storage–yield–reliability models using the Levenberg–Marquardt algorithm. 326: 215-230.
- Akaike, H. 1974. A new look at statistical model identification, in IEFÉ transactions on automatic control, 19: 716-723.
- Aal Faraj, A., and Al Haidary, A.2006. Measurement and simulation of camel core body temperature response to ambient temperature, Int. J. Agric. Biol. 8: 531–534.
- Allende H., Moraga C., and Salas R. 2002. Artificial Neural Networks in Time Series Forecasting: A Comparative Analysis. Kybernetika, 38: 685-707.
- Auliciems A., and Szokolay S. V. 1999. Thermal comfort. PLEA Notes, Brisbane (Australia), PLEA: Passive and Low Energy Architecture, Department of Architecture. University of Queensland.
- Boaventura Cunha, J., Ruano, A.E.B., and Couto, C. 1997. Identification of greenhouse climate dynamic models, Sixth International Conference on computers in agriculture, Cancun, México 161-171.
- Bornehag C., Sundell J., Sigsgaard T. 2004. Dampness in buildings and health (DBH): report from an ongoing epidemiologic investigation on the association between indoor environmental factors and health effects among children in Sweden. Indoor Air 14, 59-66.
- Bot, G.P.A. 1983. Greenhouse climate: from physical processes to a dynamic model. PhD Thesis. Wageningen. The Netherlands, 240.

- Campbell, C., and A. Temporel. 2002. An investigation of the delta rule and gradient descent algorithm. 65-77.
- Castañeda-Miranda, R., Ventura-Ramos, E. Jr., Peniche Vera, R. R., and Herrera Ruiz, G. 2006. Fuzzy greenhouse climate control system based on a field programmable gate array. *Biosyst. Engine.* 2:165–177.
- Chen, T. Y. 2002. Application of adaptive predictive control to a floor heating system with a large thermal lag, *Energy and Buildings.* 34: 45-51.
- Chen, T. Y., and Athienitis, A. K. 2003. Investigation of practical issues in building thermal parameter estimation, *Building and Environment.* 38: 1027-1038.
- Chen, T. Y. 2001. Real-time predictive supervisory operation of building thermal systems with thermal mass, *Energy and Buildings.* 33 141-150.
- Cross BS, Harrison RF, and Kennedy RL. 1997. Introduction to neural networks. *Lancet.* 346:1075-1079.
- Deltour, J., de Halleux D., Nijskens J., Coutisse S., and Nisen A. 1985. Dynamic modeling of heat and mass transfer in greenhouses. *Acta Horticulturae* 174:119-126.
- Department of Electrical Engineering. 1995. Linköping University, Ph.D. Thesis. 381.
- Fanger P.O. 1972. *Thermal Comfort*, McGraw Hill, New York, USA.
- Ferreira, P.M., E.A. Faria and A.E. Ruano, 2002. Neural network models in greenhouse air temperature prediction. *Neurocomputer*, 43: 51–57
- Forcada M.L., and Gori, M. 1999. Neural nets, recurrent, in John G. Webster, ed., *Wiley Encyclopedia of Electrical and Electronics Engineering*.

- García Chávez, J.A., Ríos Moreno, J.G., Vargas Vázquez, D., Herrera Ruiz, G., and Trejo Perea, M. 2011. Use of meteorology for the implementation of modeling techniques and prediction of internal temperature in public buildings, Congress, The Importance of Hydrometeorology in the Social-Economic Environment, CEA Querétaro, México. 1: 179-194.
- García Chávez, J.A., Ríos Moreno, J.G., Vargas Vázquez, D., Herrera Ruiz G., and Trejo Perea, M. 2010. Modelling temperature in intelligent buildings using neural networks, 7th International Congress of Engineering, Universidad Autónoma de Querétaro, and México. 1: xx-xx.
- García Martínez R., and Borrajo D. 2000. An integrated approach of planning, learning and executing. Journal of intelligent and robotic systems, Editorial Kluwer Academic Press, 29: 47-48.
- García Martínez, R. and Borrajo Millán, D. 1998. Learning in Unknown Environments by Knowledge Sharing. European Workshop on Learning Robots. VII. 22-32. University of Edinburg Press. Edinburgo. Escocia.
- González, P.A., and Zamarreño, J. M. 2005. Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. Energy and Buildings. 37: 595-601.
- Gouda, M. M., and Danaher, C. P. 2002. Application of an artificial neural network for modelling the thermal dynamics of a building's space and its heating system, Mathematical and Computer Modelling of Dynamical Systems, 8:333-344.
- Griño, R., 1992. Neural networks for univariate time series forecasting and their application to water demand prediction. *Neural Netw. World*, 437–450

Hava T. Siegelmann Department of Computer Science, Rutgers University, New Brunswick, NJ Eduardo D. Sontag Department of Mathematics, Rutgers University, New Brunswick, NJ

Haykin S.1994. Neural Networks: A Comprehensive Foundation, Macmillan College Publishing Company, 866 Third Ave., NY.

Hilera, J.R., and Martínez, V.J. 2000. Redes neuronales artificiales. Fundamentos, modelos y aplicaciones. Editorial Alfaomega Ra-Ma, Madrid, España. 390-410.

Hippert, H. S., Pedreira, C. E. and Souza, R. C. 2000 Combining neural networks and ARIMA models for hourly temperature forecast. Proceedings of the International Joint Conference on Neural Networks, 4, 414-419.

Hochreiter, S. and Schmidhuber, J. 1996. Bridging long time lags by weight guessing and long short term memory. In Spatiotem-poral models in biological and artificial systems.

Hontoria, L., Aguilera, J., Almonacid, F., Nofuentes, G., and Zufiria, P. 2006. Artificial neural networks applied in PV systems and solar radiation, Nova Science Publishers, Inc.

Hopcroft, J., Ullman, E., and Jeffrey D.1979. Introduction to Automata Theory, Languages, and Computation (1st Ed.). Addison-Wesley.

Horne, B. G. and Hush, D. R. 1996. Bounds on the complexity of recurrent neural network implementations of finite state machines. Neural Networks, 9: 243-252.

Hornik K., Stinchcombe M., and White H. 1989. Multilayer feedforward networks are universal approximators, 2: 5.

- Hossian, A. 2003. Sistema de asistencia para la selección de estrategias y actividades instruccionales. Tesis de Magíster en Ingeniería del Software. Instituto Tecnológico de Buenos Aires.
- Hwang, R.L., Lin, T.P., and Kuo, N.J. 2006. Field experiments on thermal comfort in campus classrooms in Taiwan, *Energy Build*, 38: 53–62.
- Imbabi M.S. 1990. Computer validation of scale model test for building energy simulation, *Int. J. Energy Res.* 14: 727–736.
- Indoor Air Quality Tools for Schools. IAQ Coordinator`s Guide, U.S. Environmental.
- Jiménez, M. J., Madsen, H., and Andersen, K.K. 2008. Identification of the main thermal characteristics of building components using MATLAB, *Building and Environment*. 43: 170–180.
- Kaklauskas, A., Kazimieras Zavadskas, E., Naimavicienė, J., Krutinis, M., Plakys V., and Venskus, D. 2010. Model for a Complex Analysis of Intelligent Built Environment, *Autom. Cons.* 19: 326–340.
- Kalogirou, S. A. 2010. Artificial neural networks in renewable energy systems applications: a review, *Renewable and Sustainable Energy Reviews*, 5:373-401.
- Krüger, E.L., and Zannin, P.H.T.2004. Acoustic, thermal and luminous comfort in classrooms, *Build. Environ*, 39: 1055–1063.
- Lafont, F., and Balmat, J.F. 2002. Optimized fuzzy control of a greenhouse, *Fuzzy Sets Syst.*, 128: 47–59.
- Laserna. 2000. Edificios Inteligentes y Domótica. Barcelona. Editorial Logical Design. The Data Acquisition systems. México, Omega. p. 367

- Ljung, L., and Glad, T. 1994. Modeling of dynamic systems, Prentice-Hall, New Jersey.
- Ljung, L. 1999 System identification. Theory for the User. Prentice-Hall, New Jersey, USA. 609.
- López Cruz, I., Rojano Aguilar, A., Ojeda Bustamante, W., and Salazar Moreno, R. 2007. ARX models to predict air temperature in a greenhouse: a methodology, 41: 181-192.
- Loveday, D. L., and Virk, G. S. 1992. The effectiveness of predictive control applied to warm air heating systems for commercial buildings, SERC Final Report, Contract GR/F/02014, Science and Engineering Research Council, Swindon.
- Martí M.C. 1988. Determinación de contaminantes biológicos en ambientes cerrados Proc. I Conferencia Nacional de Higiene Industrial. Valencia, Noviembre. 16-18.
- Martínez Albaladejo, A. 2003. Evaluación de la predicción de heladas en el área de Lleida. En V Simposio Nacional de Predicción. Madrid.
- McCulloch, W. S., and Pitts W. 1943. A logical calculus of the ideas immanent in neurons activity, Bull. Math. Biophys., 5:115-133.
- Mechaqrane M., and Zouak M. 2004. A comparison of linear and neural network ARX models applied to a prediction of the indoor temperature of a building, Neural. Comput. Appl. 13: 32–37.
- Montero Laurencio, R., Pérez Tello, C., Gongora Leyva, E., and Marrero Ramírez, S. 2009. Prediction of electricity and LPG consumption in a hotel using artificial neural networks, 42:21-27.

- Myhre L., Pettersen T.D. 2003, Sustainable Construction in Norway: Climate Changes and Energy Challenges. Special Issue article in: The Future of Sustainable Construction.
- Mui, K.W., Wong, L.T., and Fong, N.K. 2010. Optimization of indoor air temperature set-point for centralized air-conditioned spaces in subtropical climates, *Autom. Cons.* 19: 709–713.
- Myhre, L., and Pettersen, T.D. 2003. Sustainable construction in Norway, Climate Changes and Energy Challenges, Special Issue article in: The Future of Sustainable Construction. 1-20.
- Neter, J., Nachtsheim, M.H.C.J., and Wasserman, W. 1996. Applied linear statistical models, 4th ed., Irwin.
- Nilsson, Per-Erik and the Commtech Group. 2003. Achieving the Desired Indoor Climate, Energy Efficiency Aspects of System Design, Studentlitteratur, Lund, Sweden.
- Norma Oficial Mexicana. 1999. NOM-001-stps-1999.
- Omer, A.M. 2008. Energy, environment and sustainable development, *Renewable and sustainable Energy Reviews*, 12:2265-2300.
- Pollard A., and Stoecklein A. 1998. Occupant and building related determinants on the temperature patterns in New Zealand residential buildings, Paper no.49, IPENZ Conference, Auckland, New Zealand.
- Protection Agency. May 1995. EPA Publication 402-k-95-001.
- Ríos Moreno G. J., Trejo Perea M., Castañeda M. R., Hernández G. V. M., and Herrera R. G. 2007. Modelling temperature in intelligent buildings by means of autoregressive models, *Autom. Cons.* 16: 713-722.

- Ríos Moreno, G. J., Castañeda-Miranda, R., Herrera Ruiz, G., Hernandez Guzman, V. M., Trejo Perea, M., and Rivas Araiza, E. A. 2009. Evaluation of modelling techniques to predict indoor temperature in intelligent buildings: A literature review, *Energy and Buildings: Efficiency, Air Quality and Conservation*. Nova Science Publishers, Inc.
- Ruano, A. E., Crispim, E. M., Conceic, E. Z. E., and Lúcio, M. M. J. R. 2006. Prediction of building's temperature using neural networks models, *Energy and Buildings*, 38, 682-694.
- Rudin W.1964. Principles of Mathematical Analysis. New York:McGraw-Hill.
- Ryan, T. 1993. Contract specs for indoor Air Quality Investigations. Professional safety. ASSE july. 20-23.
- Sargent, D.J. 2001. Comparison of artificial neural networks with other statistical approaches. Results from medical data sets. *Cancer*, 91:1636-1642.
- Silva, M.N. 2007. Arrefecimento térmico de coberturas de aviários por aspersão, com vista ao uso de água chuva no centro-oeste brasileiro. Tese de Doutorado em Engenharia Agrícola. Universidade Federal de Viçosa. 124 p.
- Sinha, S., Sanjay, K., Matsumoto, T., and Kojima, T. 2001. Application of system identification modelling to solar hybrid systems for predicting radiation, temperature and load, *Renewable Energy*, 22:281-286.
- Sjöberg, Jonas. (1995). Nonlinear Black-box Modeling in System Identification: a Unified Overview. *Automatica*. 31.12: 1691-1724.

- Soleimani M., Thomas, B., and Fahlén, P. 2006. Estimation of operative temperature in buildings using artificial neural networks. *Energy and Buildings*, 38, 635-640.
- Szokolay, S. V., 1984. Passive and low energy for thermal design and visual comfort. Proceedings of the International Conference on Passive and Low Energy Ecotechniques Applied to Housing. PLEA 84. Pergamon Press. México.
- Thomas, B.; Soleimani-Mohseni, M. 2007. Artificial neural network models for indoor temperature prediction: investigations in two buildings. *Neural Computing and Applications*, 16, 81-89.
- Tkacz, G. and Hu, S. 1999. Forecasting GDP Growth Using Artificial Neural Networks, Bank of Canada.99-3.
- Trčka, M., and Hensen, J. L.M. 2010. Overview of HVAC system simulation, *Autom. Cons.* 19: 93–99
- Trejo Perea, M., Ríos Moreno, G. J., Castañeda Miranda, R., Rivas Araiza, E. A., and Herrera-Ruiz, G.2009. Greenhouse energy consumption prediction using neural networks models, *International Journal of Agriculture & Biology (IJAB)*, 11:1-6.
- Trejo Perea, M., Ríos Moreno, G.J., Herrera-Ruiz, G., Castañeda Miranda, R., Vargas-Vazquez, D., and Rivas Araiza, E. A. 2009. Load predictor for air conditioning systems using artificial neural networks models for intelligent buildings, *Air Conditioning System*. Nova Science Publishers, Inc.
- Trejo Perea, M., Ríos Moreno, J.G., Rivas, E., and Rauch, V.2005. Savings and analysis of the consumption and quality of the energy, 1er International Congress of Engineering, Universidad Autónoma de Querétaro, México, 1: 253–261.

- Trujillano, J., March, J., Badia, M., Rodríguez, A., and Sorribas, A. 2003. Application of artificial neural networks for risk stratification of hospital mortality, 17:504-511.
- U.S. Department of Energy. 2004. Energy Efficiency and Renewable Energy, Buildings Energy Databook, <http://buildingsdatabook.eren.doe.gov/>.
- Uchida Frausto, H., Pieters, J. G., and Deltour, J. M. 2003. Modelling greenhouse temperature by means of autoregressive models, biosystems engineering, 84:147-157.
- Ventura, S., M. Silvia, D. Pérez-Bendito and C. Hervás, 1995. Artificial neural networks for estimation of kinetic analytical parameters. *Anal.Chem.*, 67: 1521–1525.
- Venkatasubramanian, V., Rengaswamy R., and Kavuri S.N.2003. A review of process fault detection and diagnosis Part II: Qualitative model and search strategies, *Computers and Chemical Engineering*, 27:313-326.
- Wang, S., and Boulard T. 2000. Predicting the microclimate in a naturally ventilated plastic house in a Mediterranean climate. *J. Agric. Eng. Res.* 75: 27-38.
- White, H.1992. *Artificial Neural Networks: Approximation and Learning Theory*. Basil Blackwell, Oxford.
- Widrow, B., and Hoff, M. E. 1960. Adaptive switching circuits. 1960 IRE WESCON Convention Record. New York IRE. 96–104.
- Wong J.K.W., Li H., and Wang S.W. 2005. Intelligent building research: a review, *Autom. Constr.* 14:143–159.

Yee P. and Haykin S. 1999. A Dynamic Regularized Gaussian Radial Basis Function Network for Nonlinear, Nonstationary Time Series Prediction, IEEE Signal Processing Society. 47:2503-2521.

Yiu, J. C. M.; Wang, S. 2007. Multiple ARMAX modeling scheme for forecasting air conditioning system performance. Energy Conversion and Management, 48, 2276-2285.