

UNIVERSIDAD AUTÓNOMA CHAPINGO

**POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA**

**SIMULACIÓN DE FOTOSÍNTESIS FOLIAR EN TOMATE BAJO
INVERNADERO MEDIANTE MODELOS TEÓRICOS Y
MEDICIONES DE FITOMONITOREO**

TESIS

QUE COMO REQUISITO PARCIAL

PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO

INTEGRAL DEL AGUA ORIENTACIÓN BIOSIST.



PRESENTA:

JOSÉ MANUEL VARGAS SÁLLAGO

**DIRECCION GENERAL ACADEMICA
DEPTO. DE SERVICIOS ESCOLARES
OFICINA DE EXAMENES PROFESIONALES**

ENERO DE 2011

Chapingo, Estado de México.

**SIMULACIÓN DE FOTOSÍNTESIS FOLIAR EN TOMATE BAJO
INVERNADERO MEDIANTE MODELOS TEÓRICOS Y
MEDICIONES DE FITOMONITOREO**

Tesis realizada por **José Manuel Vargas Sállago** bajo la dirección del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

**MAESTRO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA ORIENTACIÓN BIOSISTEMAS**

DIRECTOR:



Dr. Irineo L. López Cruz

COORDIRECTOR:




Dr. Felipe Sánchez del Castillo

ASESOR:



Dra. Raquel Salazar Moreno

ASESOR:



Dr. Abraham Rojano Aguilar

DEDICATORIAS

La redacción de este trabajo no hubiese sido posible sin el apoyo incondicional de dos seres humanos que para mí son excelentes personas, ejemplo de entereza, fuerza y cariño:

Mi mamá: Josefina Sállago Vera

y

Mi papá: Manuel Vargas Pacheco

Muchas gracias por ser los arquitectos incansables de mi vida.

A Maricarmen Sandoval Sánchez, por el apoyo mostrado durante las horas interminables en que redacté la Tesis, pero sobre todo, por ser la mejor mujer que Dios me pudo haber mandado para ser mi compañera y mamá de mi primera hija:

MARÍA FERNANDA

“Aunque aún no ves la luz del sol, ten por seguro que cada día, cada esfuerzo extra es por ti”

!! y lo doy con todo el gusto del mundo!!

A mis hermanos, porque para mí, cada uno es pieza indispensable en mi vida:

Rafael, Anabel, Yamed y Maribel

De manera general a todos mis amigos y amigas que aunque sin saberlo, han sido un apoyo moral muy importante para mí.

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo (UACH) y al Posgrado en Ingeniería Agrícola y Uso Integral del Agua por haberme dado la oportunidad de realizar mis estudios de Maestría.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el apoyo económico tanto para mi formación académica a nivel Maestría, como para la realización de todas las fases de esta investigación.

Al Dr. Irineo L. López Cruz por todo el apoyo académico y logístico a lo largo de cada una de las diferentes fases de esta investigación. Muchas gracias por la dirección de este trabajo, así como por su paciencia y comprensión.

Al Dr. Ramón Arteaga Ramírez, por su valiosa ayuda en la tramitación de una Beca Mixta ante el CONACYT, misma que hizo posible mi estancia en el extranjero.

Muy sinceramente a la Dra. Raquel Salazar Moreno, Coordinadora del Programa Universitario de Investigación en Matemáticas, Estadística, Cómputo e Informática de la UACH, por apoyarme con las gestiones necesarias para realizar una fase de esta Investigación en la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín, Alemania. Así como por aportar ideas que enriquecieron la Tesis.

Al Dr. Enrique Rico García, director de la Maestría en Biosistemas de la Universidad Autónoma de Querétaro, así como al Dr. Uwe Schmidt, director de la División de Ingeniería en Biosistemas de la Facultad de Agricultura y Horticultura de la Universidad Humboldt de Berlín; ambos, por facilitar el uso del equipo de Fitomonitoreo e instalaciones para la realización de esta investigación, así como por su valioso apoyo durante las fases experimentales.

Al Dr. Felipe Sánchez del Castillo y al Dr. Abraham Rojano Aguilar, por sus acertadas sugerencias para la mejora de este documento.

Por ser buenos amigos y compañeros del Posgrado: Cuauhtémoc Pérez Vega, Carlos Robles Bañuelos, Daniel Espejel Trujano, Evaristo Camacho morales, Estela Jiménez, Agustín Ruíz García, Wael Mohamed Aly Elmessery, Carlos León, Osias Ruíz A. ...

DATOS BIOGRÁFICOS

Nace el 18 de Mayo de 1984 en el Municipio de Tolcayuca, Hidalgo. Ingres a la Universidad Autónoma Chapingo para dar comienzo a su formación Agrícola a nivel Preparatoria en 1999. Para el año 2002 inicia sus estudios de Ingeniería Mecánica Agrícola dentro de la misma Universidad, concluyéndolos en 2006, obteniendo durante la sustentación de su examen profesional la Mención Honorífica al trabajo realizado. En 2008 se incorpora al Posgrado en Ingeniería Agrícola y Uso Integral del Agua como alumno de Maestría.

Sus áreas de investigación son la Mecanización Agrícola, Modelación y Control Climático en Sistemas de Agricultura Protegida.

SIMULACIÓN DE FOTOSÍNTESIS FOLIAR EN TOMATE BAJO INVERNADERO MEDIANTE MODELOS TEÓRICOS Y MEDICIONES DE FITOMONITOREO

SIMULATION OF GREENHOUSE TOMATO LEAF PHOTOSYNTHESIS BY THEORETICAL MODELS AND PHYTOMONITORING MEASUREMENTS

José Manuel Vargas Sállago^a, Irineo L. López Cruz^b

Resumen

Se simuló la tasa de fotosíntesis foliar de plantas de tomate, cultivadas bajo invernadero, empleando el modelo mecanicista de Goudriaan y dos modelos de caja negra: Modelos Auto-regresivos de Variables Exógenas (ARX) y Redes Neuronales Artificiales (ANN). Las mediciones de las tasas de fotosíntesis foliar, se realizaron en tres diferentes invernaderos experimentales, uno localizado en la Universidad Autónoma de Querétaro, México y dos en la Universidad Humboldt de Berlín, Alemania. Se usó el Fitomonitor PTM-48M (Daletown Company Ltd.) para el registro del intercambio de dióxido de carbono (CO₂) de las hojas. Además se midieron también la temperatura del aire, humedad relativa, radiación fotosintéticamente activa (PAR), concentración de CO₂ y déficit de presión de vapor (VPD). Estas variables meteorológicas fueron usadas como entradas de los modelos ARX y de los modelos de redes neuronales de retropropagación. El modelo mecanicista reportó errores de 6.7%, 12.6% y 13.7% entre los valores resultantes de las simulaciones contra los valores medidos, para los tres invernaderos respectivamente. Las Redes Neuronales tuvieron errores de 4.6%, 4.7% y 5.6%. Por el contrario, el mejor modelo ARX presentó una R² apenas superior al 50%. Tomando los resultados de los mejores modelos (ANN) se realizó una optimización estática, relacionando dos variables climáticas con la tasa de fotosíntesis (mediante gráficas 3D) a fin de encontrar estrategias para maximizar esta última variable.

Palabras clave: Redes neuronales, Modelo mecanicista de fotosíntesis, Modelo Auto-regresivo de variables exógenas (ARX).

Abstract

Greenhouse tomato leaf photosynthesis rate was simulated by means of the Goudriaan's mechanistic model, and two black-box models: Auto-regressive with external variables (ARX) models and Artificial Neural Networks (ANN). Measurements of the leaf photosynthesis rates were carried out in three different experimental greenhouses, one located at the University of Queretaro, Mexico and two at the Humboldt University of Berlin, Germany. A PTM-48M phytomonitor (Daletown Company, Ltd.) was used to record the carbon dioxide (CO₂) interchange in the leaves. Furthermore, the air temperature, relative humidity, photosynthetically active radiation (PAR), CO₂ concentration, and vapor pressure deficit (VPD) were measured. These meteorological variables were used as the inputs for both the ARX and the backpropagation neural network models. The mechanistic model reported errors of 6.7%, 12.6%, and 13.7% among values predicted by simulations and measurements, for the three greenhouses, respectively. Neural Networks had errors of 4.6%, 4.7% y 5.6%. On the contrary, the best ARX model had a R² barely greater than 50%. Taking the best results obtained by the best models (ANN) a static optimization was carried out, relating two climatic variables with the photosynthesis rate (by 3D plots) in order to find strategies to maximize this last variable.

Key words: Neural Networks, Mechanistic photosynthesis model, Auto-regressive with external variables model (ARX).

^aTesista

^bDirector

^aThesis author

^bThesis director

INDICE GENERAL

RESUMEN.....	VI
INDICE DE CUADROS.....	X
INDICE DE FIGURAS.....	XIII
1. INTRODUCCIÓN	1
2. REVISIÓN DE LITERATURA	4
2.1 Elementos que influyen en la asimilación de CO ₂	4
2.2 Microclima del Invernadero	5
2.2.1 Radiación Solar	7
2.2.2 Temperatura	8
2.2.3 Humedad Relativa.....	9
2.2.4 Concentración de Dióxido de Carbono	11
2.2.5 Déficit de Presión de Vapor	13
2.3 Tecnología de Fitomonitorio	14
2.4 Modelación Matemática de cultivos.....	16
2.4.1 Modelos Mecanicistas de Fotosíntesis.....	18
2.4.2 Modelos de Caja Negra.....	22
3. MATERIALES Y MÉTODOS	24
3.1 Invernadero Experimental del Campus Amazcala de la Universidad Autónoma de Querétaro.	24
3.2 Invernaderos Experimentales de la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín.	26
3.3 Fórmula para calcular la Fotosíntesis Foliar.	28
3.4 Pre-procesamiento de datos.....	32
3.5 Pre-procesamiento de datos para la Identificación de Sistemas.....	35

3.6	Modelo Mecanicista para Fotosíntesis Foliar.....	40
3.7	Redes Neuronales.	46
3.8	Generación de las Rutas de la Fotosíntesis.....	52
4.	RESULTADOS Y DISCUSIÓN	54
4.1	INVERNADERO EXPERIMENTAL DEL CAMPUS AMAZCALA DE LA UNIVERSIDAD AUTÓNOMA DE QUERÉTARO	54
4.1.1	Comportamiento de las variables climáticas que afectan la fotosíntesis. ..	55
4.1.1.1	Fotosíntesis vs Radiación	55
4.1.1.2	Fotosíntesis vs Temperatura	56
4.1.1.3	Fotosíntesis vs Humedad Relativa.....	57
4.1.1.4	Fotosíntesis vs Concentración de CO ₂	58
4.1.1.5	Fotosíntesis vs Déficit de Presión de Vapor	60
4.1.2	Metodología de la Identificación de Sistemas aplicada a Fotosíntesis.	62
4.1.3	Modelo Mecanicista de Goudriaan para predicción de la Fotosíntesis Foliar.....	69
4.1.4	Redes Neuronales aplicadas al Sistema Fotosíntesis	80
4.1.4.1	Simulación de la mejor Red Neuronal	82
4.1.5	Ruta de la Fotosíntesis en función de la relación entre dos variables climáticas.	87
4.1.5.1	Fotosíntesis vs Temperatura - Concentración de CO ₂	87
4.1.5.2	Fotosíntesis vs Radiación - Déficit de Presión de Vapor	89
4.1.5.3	Fotosíntesis vs Humedad Relativa - Concentración de CO ₂	91
4.1.5.4	Fotosíntesis vs Déficit de Presión de Vapor - Concentración de CO ₂	93
4.1.5.5	Fotosíntesis vs Temperatura - Humedad Relativa	95

4.2	INVERNADEROS EXPERIMENTALES DE LA DIVISI3N DE INGENIERÍA EN BIOSISTEMAS, UNIVERSIDAD HUMBOLDT DE BERLIN...	98
4.2.1	Comportamiento de las variables climáticas que afectan la fotosíntesis. ...	99
4.2.1.1	Fotosíntesis vs Radiación	99
4.2.1.2	Fotosíntesis vs Temperatura	102
4.2.1.3	Fotosíntesis vs Humedad Relativa.....	103
4.2.1.4	Fotosíntesis vs Concentraci3n de CO ₂	104
4.2.1.5	Fotosíntesis vs Déficit de Presi3n de Vapor	106
4.2.2	Metodología de la Identificaci3n de Sistemas aplicada a Fotosíntesis. ...	109
4.2.3	Modelo Mecanicista de Goudriaan para predicci3n de la Fotosíntesis Foliar.....	110
4.2.4	Redes Neuronales Aplicadas al Sistema Fotosíntesis.	122
4.2.4.1	Simulaci3n con la mejor Red Neuronal del Sistema Convencional.	127
4.2.4.2	Simulaci3n con la mejor Red Neuronal del Sistema Des-Fog.	130
4.2.5	Ruta de la Fotosíntesis en funci3n de la relaci3n entre dos variables climáticas.	135
4.2.5.1	Fotosíntesis vs Temperatura - Concentraci3n de CO ₂	135
4.2.5.2	Fotosíntesis vs Radiaci3n –Déficit de Presi3n de Vapor.....	137
4.2.5.3	Fotosíntesis vs Temperatura – Humedad Relativa	139
5.	CONCLUSIONES	142
	BIBLIOGRAFIA.....	148
	APÉNDICE A. NOTACI3N.....	154

INDICE DE CUADROS

Cuadro 1. Mejores Modelos ARX obtenidos, usando 80% de los datos para estimación y 20% para validación del modelo.	63
Cuadro 2. Mejores Modelos ARX obtenidos, usando 60% de los datos para estimación y 40% para validación del modelo.	64
Cuadro 3. Valores semilla propuestos para cada una de las 10 calibraciones.	71
Cuadro 4. Calibraciones del día Juliano 311 (07 de Noviembre de 2009) para la Variable de salida Fotosíntesis.....	72
Cuadro 5. Calibraciones del día Juliano 311 (07 de Noviembre de 2009) para las Variables de salida Fotosíntesis y PAR.	72
Cuadro 6. Calibraciones de los días Julianos 339 al 343 (05 -09 de diciembre de 2009) para la Variable de salida Fotosíntesis.	72
Cuadro 7. Calibraciones de los días Julianos 339 al 343 (05 -09 de diciembre de 2009) para las Variables de salida Fotosíntesis y PAR.	73
Cuadro 8. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis para Querétaro.	74
Cuadro 9. Estadísticos de las mejores configuraciones de red para los datos no filtrados.	81
Cuadro 10. Estadísticos de las mejores configuraciones de red para los datos filtrados por medio del método Savitzky Golay.....	81
Cuadro 11. Comparación entre las mejores redes neuronales para cada tipo de datos de entrada.	82
Cuadro 12. Valores semilla propuestos para cada una de las 10 calibraciones.	111

Cuadro 13. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Convencional.	112
Cuadro 14. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Convencional.	112
Cuadro 15. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Convencional.	112
Cuadro 16. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Convencional. ..	113
Cuadro 17. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Des-Fog.	113
Cuadro 18. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Des-Fog.	113
Cuadro 19. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Des-Fog.	114
Cuadro 20. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Des-Fog.	114
Cuadro 21. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis. Sistema Convencional.	115
Cuadro 22. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis. Sistema Des-Fog.	116
Cuadro 23. Estadísticos de las mejores conFiguraciones de red para los datos no filtrados. Sistema Convencional.	123
Cuadro 24. Estadísticos de las mejores conFiguraciones de red para los datos filtrados. Sistema Convencional.	124

Cuadro 25. Comparación entre las mejores Redes Neuronales del Sistema Convencional.	125
Cuadro 26. Estadísticos de las mejores conFiguraciones de red para los datos no filtrados. Sistema Des-Fog.	125
Cuadro 27. Estadísticos de las mejores conFiguraciones de red para los datos filtrados. Sistema Des-Fog.	126
Cuadro 28. Comparación entre las mejores Redes Neuronales del Sistema Des-Fog. ..	126

INDICE DE FIGURAS

Figura 2.1) Representación esquemática de un estoma. Fuente, Boletín 56 FAO, 2006...	5
Figura 3.1) Invernaderos experimentales del Campus Amazcala de la Universidad Autónoma de Querétaro.	24
Figura 3.2) Sensores instalados en el experimento. Izquierda, 2 cámaras de monitoreo y sensor ventilado para temperatura y humedad relativa del PTM-48M. Derecha, sensor de radiación PAR.	25
Figura 3.3) Invernaderos experimentales de la Facultad de Horticultura de la Universidad Humboldt de Berlín.	27
Figura 3.4) Sensores empleados para monitorear las condiciones del cultivo. Izquierda, PTM-48M; derecha, PTF-30.	28
Figura 3.5) Filtro Savitzky-Golay aplicado a datos de radiación.....	33
Figura 3.6) Diferentes coeficientes Savitzky-Golay para filtrar radiación. El tipo de filtro depende del comportamiento de la variable medida.	34
Figura 3.7) Filtros aplicados a los datos de fotosíntesis..	35
Figura 3.8) Esquema de una Red Neuronal Multicapa.	47
Figura 4.1) Fotosíntesis vs Radiación PAR en los primeros cinco días de mediciones. .	55
Figura 4.2) Comportamiento de la Radiación PAR a lo largo de un día.	56
Figura 4.3) Fotosíntesis vs Temperatura en los primeros cinco días de mediciones.	57
Figura 4.4) Fotosíntesis vs Humedad Relativa en los primeros cinco días de mediciones.	58
Figura 4.5) Fotosíntesis vs Concentración de CO ₂ durante cuatro días de mediciones. .	59

Figura 4.6) Trayectoria de la concentración de CO ₂ al interior del invernadero como respuesta de los procesos de fotosíntesis y respiración.....	60
Figura 4.7) Fotosíntesis vs Déficit de Presión de Vapor durante 4 días de mediciones. .	61
Figura 4.8) Variables climáticas que afectan el proceso de Fotosíntesis.....	62
Figura 4.9) Simulación del mejor Modelo ARX. El grado de ajuste es del 50.3%	65
Figura 4.10) Predicción del Modelo ARX. El grado de ajuste se incrementa a 89.61%.	65
Figura 4.11) Función de Autocorrelación de los residuales para el Modelo ARX.	66
Figura 4.12) Función de Correlación cruzada entre la variable de entrada Radiación y residuales de la variable de salida Fotosíntesis.	66
Figura 4.13) Función de Correlación cruzada entre la variable de entrada Temperatura y residuales de la variable de salida Fotosíntesis.	67
Figura 4.14) Función de Correlación cruzada entre la variable de entrada Humedad Relativa y la variable de salida Fotosíntesis.	67
Figura 4.15) Función de Correlación cruzada entre la variable de entrada Déficit de Presión de Vapor y la variable de salida Fotosíntesis.	67
Figura 4.16) Función de Correlación cruzada entre la variable de entrada CO ₂ y la variable de salida Fotosíntesis.....	67
Figura 4.17) La tasa máxima de fotosíntesis (<i>A_{max}</i>) es un parámetro medido a lo largo de los días de estudio.....	70
Figura 4.18) Fotosíntesis Teórica vs Medida para los días Julianos 339-343.	75
Figura 4.19) Regresión Fotosíntesis para los días Julianos 339 - 343.	75
Figura 4.20) Radiación PAR medida por el sensor dentro del invernadero vs PAR teórica. Dias Julianos 339 – 343.	76

Figura 4.21) Regresión Radiación Fotosinteticamente Activa Disponible para los días Julianos 339-343.	76
Figura 4.22) Radiación Teórica Absorbida por el Dosel vs Radiación PAR Medida dentro del Invernadero. Días Julianos 339- 343.....	77
Figura 4.23) La declinación de la Fotosíntesis está en función de la elevación solar a través del tiempo. Se grafica para los días 307 al 361.	77
Figura 4.24) Fotosíntesis Teórica del modelo SUCROS vs Fotosíntesis medida para el día Juliano 311.	78
Figura 4.25) PAR Teórica vs PAR medida para el día Juliano 311.....	79
Figura 4.26) Ajuste de la mejor Red Neuronal para los subconjuntos: entrenamiento, validación y prueba..	83
Figura 4.27) Comportamiento de la Fotosíntesis al simular la mejor Red neuronal, cuando se ingresa la matriz de variables de entrada de tamaño 4820 x 5.	84
Figura 4.28) Simulación de la ANN para los datos de seis días.	84
Figura 4.29) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones.....	85
Figura 4.30) Fotosíntesis en función de las variables Temperatura y Concentración de CO ₂	88
Figura 4.31) Fotosíntesis en función de las variables PAR y VPD..	90
Figura 4.32) Fotosíntesis en función de las variables Concentración de CO ₂ y Humedad Relativa..	92
Figura 4.33) Fotosíntesis en función de las variables Concentración de CO ₂ y VPD.. ...	94
Figura 4.34) Fotosíntesis en función de las variables Humedad Relativa y Temperatura..	96

Figura 4.35) Fotosíntesis vs Radiación PAR durante los días Julianos 253-255.....	99
Figura 4.36) Trayectoria de la Radiación Fotosintéticamente Activa a lo largo del periodo de mediciones.....	100
Figura 4.37) Comportamiento de la Radiación Fotosintéticamente Activa al interior del invernadero durante un día.....	101
Figura 4.38) Distribución de la Radiación Fotosintéticamente Activa en la superficie del invernadero, durante un lapso de 1 hora en 140 puntos de medición.	101
Figura 4.39) Fotosíntesis vs Temperatura durante los días Julianos 253-255.	102
Figura 4.40) Fotosíntesis vs Humedad Relativa durante los días Julianos 253-255.....	104
Figura 4.41) Fotosíntesis vs Concentración de CO ₂ durante los días Julianos 253-255.	105
Figura 4.42) Concentración de CO ₂ al interior de los invernaderos para el día Juliano 253.....	106
Figura 4.43) Fotosíntesis vs Déficit de Presión de Vapor durante los días Julianos 253-255.....	107
Figura 4.44) Variables climáticas que afectan el proceso de Fotosíntesis. De arriba hacia abajo, Tasa de Fotosíntesis, Temperatura, Humedad Relativa, Concentración de CO ₂ , Déficit de Presión de Vapor y, Radiación PAR.	108
Figura 4.45 Ajuste de los mejores modelos de caja negra para el Sistema Convencional.	109
Figura 4.46) La tasa máxima de fotosíntesis (<i>A_{max}</i>) es un parámetro medido a lo largo de los días de estudio.....	110
Figura 4.47) Fotosíntesis Teórica vs Medida para los días Julianos 234-237. Sistema Convencional.....	118

Figura 4.48) Regresión para Fotosíntesis en los días Julianos 234-237. Sistema Convencional.....	118
Figura 4.49) Fotosíntesis Teórica vs Medida para los días Julianos 234-237. Sistema Des-Fog.....	119
Figura 4.50) Regresión para Fotosíntesis en los días Julianos 234-237. Sistema Des-Fog.	119
Figura 4.51) Radiación PAR medida por el sensor dentro del invernadero vs PAR teórica. Días Julianos 234-237, aplica a ambos sistemas.....	120
Figura 4.52) Regresión para Radiación Fotosinteticamente Activa Disponible en los días Julianos 234-237.	120
Figura 4.53) La declinación de la Fotosíntesis está en función de la elevación solar a través del tiempo. Se grafica para los días 231 al 329, sistema Convencional.	122
Figura 4.54) Ajuste de la mejor Red Neuronal del Sistema Convencional de acuerdo con el Neural Network Toolbox Graphical User Interface de MATLAB.	128
Figura 4.55) Simulación de la mejor ANN para los datos del Sistema Convencional.	128
Figura 4.56) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones del Sistema Convencional.	129
Figura 4.57) Ajuste de la mejor Red Neuronal del Sistema Des-Fog, de acuerdo con el Neural Network Toolbox Graphical User Interface de MATLAB.	131
Figura 4.58) Simulación de la mejor ANN para los datos del Sistema Des-Fog.....	132
Figura 4.59) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones del Sistema Des-Fog.	133
Figura 4.60) Fotosíntesis en función de las variables Temperatura y Concentración de CO ₂	136

Figura 4.61) Fotosíntesis en función de las variables Radiación y VPD.....138

Figura 4.62) Fotosíntesis en función de las variables Temperatura y Humedad Relativa..
.....140

1. INTRODUCCIÓN

El mejoramiento del control ambiental dentro del invernadero requiere identificar la influencia de factores climáticos en la fisiología y desarrollo de las plantas cultivadas, puesto que la respuesta de la planta es la parte del proceso más importante en los sistemas de producción (Tantau, 1992; Roh, 2007).

Dentro de los aspectos fisiológicos más relevantes que deben ser considerados en un sistema de producción en invernadero, se encuentra el entendimiento del proceso de fotosíntesis y los elementos que influyen en ella positiva o negativamente (Evans *et al.*, 2000). El proceso de fotosíntesis está relacionado con la transformación del dióxido de carbono (CO_2) y agua en asimilados que la planta emplea para su mantenimiento, crecimiento y desarrollo. La tasa de fotosíntesis es influenciada principalmente por la intensidad de luz, concentración de CO_2 y por la temperatura (Van Ooteghem, 2007), aunque otras variables climáticas tienen bastante influencia en este proceso.

La mayoría de las acciones de control climático afectan más variables de las que debieran y por lo tanto pueden alterar las resistencias internas y externas de la hoja al intercambio gaseoso; de acuerdo con esto, las acciones de control y efectividad de estos procedimientos deben ser cuidadosamente propuestos cuando el objetivo sea un buen control de temperatura y transpiración del dosel, (Wilkinson, 2000). Por ejemplo, la sola

manipulación de la humedad relativa dentro de un invernadero no es por sí misma un sustituto del manejo que se debe hacer para modificar la tasa de transferencia del follaje, sin embargo, juega un papel muy importante en las tasas de intercambio gaseoso (vapor de agua y CO_2) (Stanghellini, 1988).

El monitoreo en tiempo real y continuo de la respuesta fisiológica de la planta a los cambios del ambiente, proporciona información muy importante para controlar el microclima del invernadero de forma precisa; así mismo, el uso de esta tecnología es muy acertado como una herramienta para hacer investigación (Ton, 2001). Sin embargo, adaptar una tecnología de fitomonitorio a sistemas de producción convencional bajo invernadero resulta casi imposible por los elevados costos de los equipos (Roh, 2007).

Afortunadamente, la modelación de ciertos procesos como la fotosíntesis es una herramienta que permite conocer el comportamiento de los cultivos bajo ciertas condiciones ambientales de forma muy económica, sólo es necesario contar con modelos que lleven a cabo la predicción de manera eficiente.

Los modelos de fotosíntesis y de cultivos pueden ser usados para identificar las condiciones deseadas de crecimiento, explorar efectos de las condiciones de desarrollo relacionadas a la introducción de nuevas tecnologías, así como a la identificación de tratamientos que son particularmente importantes en un ambiente específico (Marcelis, Heuvelink, 2009).

Muchos modelos mecanicistas de fotosíntesis han sido propuestos en el pasado, sin embargo, se les puede agrupar en dos grandes ramos: 1) modelos de hoja, que describen la tasa de fotosíntesis de una hoja simple, ó 2) modelos de cultivos, en los que se reporta la fotosíntesis del follaje como un todo. En principio, la fotosíntesis del dosel puede ser obtenida a partir de la fotosíntesis de hoja mediante una integración especial.

Además de los modelos de fotosíntesis, otros modelos matemáticos han sido usados para predecir el comportamiento de las variables climáticas en los invernaderos, sin embargo, algunos de estos modelos son difíciles de implementar. Debido a lo anterior, en los últimos años, los modelos de caja negra han sido exitosamente usados en ésta área, por ejemplo los Auto-regresivos con Variables Exógenas (ARX) (López *et al.*, 2007), así como las Redes Neuronales Artificiales (ANN). Estas últimas tienen la capacidad de modelar variables altamente no lineales (Salazar *et al.*, 2008).

El objetivo de esta investigación fue encontrar un modelo matemático que describa de manera eficiente el comportamiento de la tasa de fotosíntesis foliar de plantas de tomate (*Lycopersicon esculentum*), a partir de los valores de intercambio de dióxido de carbono, reportados por un sistema de fitomonitorio, y de las condiciones climáticas al interior del invernadero: radiación fotosintéticamente activa, temperatura, humedad relativa, concentración de CO₂ y déficit de presión de vapor.

Se evaluaron, el Modelo Mecanicista de Goudriaan (Goudriaan & Van Laar, 1994) y dentro de los Modelos de Caja Negra, derivados de la Teoría de Identificación de Sistemas, principalmente los Auto-regresivos de Variables Exógenas, así como las Redes Neuronales Artificiales. A partir del mejor Modelo, se generaron superficies en tres dimensiones para explicar de forma más sencilla el efecto de la interacción entre variables climáticas y su efecto en la tasa de fotosíntesis.

Las mediciones de las variables de entrada y salida para los modelos se realizaron en dos diferentes latitudes, 1) Invernaderos Experimentales de la Universidad Autónoma de Querétaro (20°42'), México, e 2) Invernaderos Experimentales de la Universidad Humboldt de Berlín (52°28'), Alemania.

2. REVISIÓN DE LITERATURA

2.1 Elementos que influyen en la asimilación de CO₂.

Las plantas transforman la energía solar en energía química por medio del proceso fisiológico de la fotosíntesis. Durante este proceso, las plantas fijan dióxido de carbono (CO₂) y liberan oxígeno (O₂), mientras controlan la pérdida de agua (H₂O) debido a la transpiración (Millan, *et al.*, 2009).

Durante el proceso de transpiración, la planta cede vapor de agua al ambiente y recolecta de él una de las moléculas más importantes para la formación de estructuras dentro de ella, el CO₂; este fenómeno se lleva a cabo por pequeñas estructuras llamadas estomas (Wilkinson, 2000). Éstas son pequeñas aberturas en la hoja de la planta (Figura 2.1) a través de las cuales se da el intercambio gaseoso. Casi toda el agua absorbida del suelo se pierde por transpiración y solamente una pequeña fracción se convierte en parte de los tejidos vegetales (Boletín 56 FAO, 2006).

Dependiendo de las condiciones ambientales de humedad y temperatura, la planta posee un mecanismo con el cual regula en mayor o menor grado la apertura estomática, favoreciendo con ello el intercambio de gases (Monteith, 1990).

Además, la transpiración, y consecuentemente la fotosíntesis, depende del aporte de energía, proveniente de la radiación solar, así como del gradiente de presión del

vapor. La tasa de transpiración también es influenciada por las características y tipo del cultivo, el medio donde se produce y las prácticas agrícolas (Boletín 56 FAO, 2006).




Figura 2.1) Representación esquemática de un estoma. Fuente, Boletín 56 FAO, 2006.

Las barreras en la difusión del agua (apertura estomática) también pueden bloquear la difusión de CO_2 , consecuentemente, cualquier cambio a las restricciones a lo largo de la ruta de intercambio afecta tanto agua como CO_2 (Evans, *et al* 2000).

2.2 Microclima del Invernadero

A lo largo del mundo, la producción en invernaderos está en constante crecimiento. Comparada con la producción en campo abierto, los invernaderos permiten lograr altos rendimientos, mejor calidad de productos, producción fuera de temporada así como un uso muy eficiente del agua. Los invernaderos varían desde construcciones simples cubiertas con plástico, hasta modernos invernaderos de vidrio con muy alta tecnología (Heuvelink, 2007).

Independientemente del tipo de invernadero, el control climático al interior del mismo está enfocado a mantener las variables climáticas de temperatura, humedad relativa, cantidad de radiación, déficit de presión de vapor y nivel de CO_2 tan cerca como

sea posible de las condiciones óptimas para el desarrollo del cultivo. Como resultado de la crisis energética en el mundo, se ha puesto más énfasis en el control ambiental de los invernaderos de tal forma que se evite la pérdida de energía y consecuentemente pérdidas económicas. En este sentido, el control climático representa un problema de optimización donde la maximización del beneficio no es necesariamente consecuencia del incremento del rendimiento (Salazar *et al.*, 2008).

El mejoramiento del control ambiental de los invernaderos y las prácticas para incrementar la producción han ayudado a los agricultores a participar en las ventanas de mercado más favorables, gracias a la integración de herramientas para la toma de decisiones que incluyen modelos de simulación de cultivos, así como sistemas de producción y de manejo (Boote, 2006).

Actualmente, el llamado “invernadero cerrado” es la innovación en la industria de invernaderos en Holanda y otros países Europeos (Schmidt *et al.*, 2008). Este tipo de invernaderos ofrece la posibilidad de controlar cantidad de radiación, temperatura, humedad relativa y concentración de gas CO₂ que en invernaderos convencionales es imposible. Con el uso de esta tecnología se han reportado reducciones de hasta 30% en el uso de energía e incrementos en la producción superiores a 20%, debido principalmente a la alta concentración constante de CO₂ (Heuvelink, 2007).

La tendencia de la mecanización de la producción bajo invernadero tiene una tendencia hacia la completa automatización de los procesos, tanto de control del microclima en que se desarrollará el cultivo, así como de las prácticas de manejo del mismo, haciendo cada vez más uso de sensores especiales e inteligencia artificial para resolver problemas como la cosecha por medio de robots con procesamiento de imágenes en 3D (van Henten, 2006).

2.2.1 Radiación Solar

La cantidad potencial de radiación que puede llegar a una superficie está determinada por su localización y época del año. Debido a las diferencias en la posición del planeta y a su movimiento alrededor del sol, esta cantidad potencial de radiación es diferente para cada latitud y para las diversas estaciones del año. La radiación solar real que alcanza una superficie depende de la turbidez de la atmosfera y de la presencia de nubes que reflejan y absorben cantidades importantes de radiación. (Boletín 56 FAO, 2006).

La Radiación Fotosintéticamente Activa (PAR, por sus siglas en inglés) se refiere a la radiación cuya longitud de onda está comprendida entre los 400 *nm* (azul), pasa por los 550 *nm* (verde) hasta los 700 *nm* (rojo) es decir, el espectro de luz visible que tiene influencia sobre el proceso fotosintético. La radiación PAR puede medirse en unidades de densidad de flujo energético (Wm^{-2}), pero también en unidades de densidad flujo de fotones ($molm^{-2}s^{-1}$) (Monteith, 1990).

Casi todas las mediciones de la radiación relacionadas a cultivos se reportan en términos de radiación fotosintéticamente activa, sin embargo hay que considerar que se puede estar hablando de radiación solar incidente total (RST), que es aproximadamente el doble de la primera (sobre todo cuando se habla de $MJm^{-2}día^{-1}$).

La fotosíntesis es un complicado proceso biológico que capacita al organismo a utilizar la radiación PAR como fuente de energía metabólica y que, por lo tanto, le permite nutrirse de compuestos minerales con bajo o nulo contenido energético. La primera etapa de la fotosíntesis consiste en la absorción de un fotón por un pigmento

orgánico que pasa a un estado electrónicamente excitado desde el que es posible iniciar una serie de transformaciones físicas y químicas específicas (Azcon-Bieto, 1993).

La cantidad, tipo y calidad de radiación incidente sobre el cultivo determina en gran medida la asimilación de moléculas de CO₂. La respuesta de los estomas a la radiación se compone de varios mecanismos de acción ligados a la fotosíntesis. Sobre un amplio rango de radiación, la conductancia estomática se incrementa proporcionalmente con la tasa de asimilación de CO₂, hasta que la presión parcial de CO₂ permanece constante (Evans, 2000).

2.2.2 Temperatura

El calor emitido por la tierra y la radiación solar absorbida por la atmosfera elevan la temperatura del aire. El calor sensible del aire circundante transfiere energía al cultivo y entonces ejerce un cierto control en diferentes procesos fisiológicos de éste (Boletín 56 FAO, 2006).

La temperatura es otro de los factores externos de gran importancia que afecta la actividad de las enzimas y los procesos a nivel membrana, influyendo de manera indirecta sobre la apertura y cierre de los estomas y por lo tanto, afectando la fotosíntesis (Lambers *et al.* 2008).

La temperatura de la hoja es la base de muchos procesos fisiológicos de las plantas, tales como la fotosíntesis, respiración, transpiración, etc. Sin embargo, a pesar de que la hoja es el sitio de muchos procesos fisiológicos, la temperatura del aire es considerada para caracterizar el ambiente de las plantas (Acock, Baldocchi, Jones, citados por Roh *et al.*, 2007).

Por ejemplo, la tasa de fotosíntesis se incrementa con la elevación de la temperatura hasta un valor máximo y luego decrece con temperaturas muy elevadas (van Ooteghem, 2007).

A nivel bioquímico, altas temperaturas limitan la actividad de la molécula Rubisco (muy importante durante la fotosíntesis), pero también se limita el proceso de transporte de electrones a través de la membrana (Lambers *et al.* 2008).

La respuesta de la fotosíntesis foliar a la temperatura, depende enormemente de la intensidad luminosa. A baja intensidad de luz, la temperatura óptima del cultivo es mucho menor que a alta intensidad de luz, y la respuesta a la temperatura es mucho más débil (Heuvelink, 2007).

Además de la fotosíntesis, la temperatura también tiene influencia en aspectos tales como división de materia, desarrollo de área foliar y desarrollo de frutos (Heuvelink, 2007).

2.2.3 Humedad Relativa

La tasa de transpiración del cultivo (proceso por el que se realiza el intercambio gaseoso) es una función de la resistencia estomática y depende de la intensidad de luz, concentración de CO₂, temperatura y humedad.

La humedad relativa es muy importante en la tasa de transferencia de CO₂, puesto que a bajos valores de humedad, la planta genera una oclusión de las aberturas estomáticas de tal forma que se reduzca la pérdida de agua por deshidratación (van Ooteghem, 2007).

Actualmente, existen diferentes métodos para incrementar el contenido de humedad al interior del invernadero, por ejemplo, el uso de sistemas de nebulización

(Fog Systems). Sin embargo, un efecto adverso del uso de éstas técnicas ocurre cuando la humedad relativa dentro del invernadero es muy elevada y la temperatura de los tejidos de la planta están por debajo del punto de condensación, ocasionando que se tengan hojas y frutos mojados, haciéndolos susceptibles a enfermedades por hongos o infecciones bacterianas (Schmidt, *et al.*, 2007; Salazar *et al.*, 2008).

Sin embargo, es necesario tener en cuenta que la sola manipulación de la humedad relativa dentro de un invernadero no es por sí misma un sustituto de la manipulación que se debe hacer para modificar de la tasa de transferencia del follaje, sin embargo juega un papel muy importante en las tasas de intercambio (Stanghellini, 1988).

La humedad relativa (HR) expresa el grado de saturación del aire como el cociente entre la presión real de vapor (e_a) a una temperatura dada y la presión de saturación de vapor ($e^\circ(T)$) a la misma temperatura (T):

$$HR = \frac{e_a}{e^\circ(T)} * 100$$

La humedad relativa es el cociente entre la cantidad de agua que el aire realmente contiene a una determinada temperatura y la cantidad que podría contener si estuviera saturado a la misma temperatura. Es adimensional y se expresa comúnmente como porcentaje. Aunque la presión real de vapor puede ser relativamente constante a lo largo del día, la humedad relativa fluctúa entre un máximo al amanecer y un mínimo a primeras horas de la tarde. La variación de la humedad relativa se produce porque la presión de saturación de vapor depende de la temperatura del aire. Como la temperatura del aire cambia durante el día, la humedad relativa también cambia substancialmente (Boletín 56 FAO, 2006).

2.2.4 Concentración de Dióxido de Carbono

El CO_2 , al ser la base de los compuestos orgánicos, es también muy importante por su baja concentración, que en general es limitante para la fotosíntesis. La concentración de CO_2 en el exterior de un invernadero se mantiene más o menos constante alrededor de 370 ppm. En el interior del invernadero la concentración de CO_2 va variando a lo largo del día. Durante el día, la planta realiza los procesos de fotosíntesis (en la que consume CO_2) y respiración (en la que produce CO_2). La concentración de CO_2 disminuye cuando la planta realiza la fotosíntesis; cuando más óptimas sean las condiciones climáticas, mayor será la tasa de fotosíntesis y por ello mayor será el consumo de CO_2 (Wilkinson, 2000).

La adquisición de CO_2 por parte de las plantas involucra la difusión del CO_2 desde el aire hasta el interior de las hojas y, finalmente, al interior de los cloroplastos. Ahí, la fijación de CO_2 en compuestos orgánicos crea un gradiente de concentración, mismo que determina la difusión del gas. El CO_2 encuentra muchos obstáculos a lo largo de su ruta hacia los cloroplastos. Las resistencias a la difusión atribuibles a la capa límite (*boundary layer*), así como a la acción de los estomas son compartidas con el flujo de agua en sentido opuesto que escapa de la hoja (Evans, 2000).

Las plantas mantienen un balance entre la pérdida de agua y la adquisición de CO_2 gracias a la respuesta de los estomas a muchas variables climáticas. Por ejemplo, la conductancia estomática puede variar en cuestión de minutos en respuesta a estos cambios del ambiente, mientras que las resistencias internas a la conductancia del gas parecen mantenerse constantes a lo largo de muchos días y dependen de las propiedades anatómicas de las hojas (Evans, 2000).

Una práctica común, en muchos países, es el adicionar dióxido de carbono a la atmósfera del invernadero para crear concentraciones elevadas de este gas, de tal forma que se incremente la tasa de fotosíntesis de las plantas. Es habitual que durante el día, las concentraciones se eleven entre 700 a 1000 *ppm*, 2 a 3 veces la concentración atmosférica normal, hasta que la ventilación se hace necesaria para limitar el incremento de la temperatura (Bailey *et al.*, 1997).

Con el calentamiento global, se esperan temperaturas más altas al exterior de los invernaderos, principalmente en verano. El intercambio de aire con ventilación forzada o natural es usado principalmente para enfriar el interior de los invernaderos; sin embargo, al abrir las ventanas vienen otros efectos negativos, como la pérdida de vapor de agua, pero principalmente de CO₂, cuando se enriquece el ambiente del cultivo con este gas. Ambos componentes son muy significantes en la optimización de las condiciones del microclima (Schmidt *et al.*, 2007). Muchos estudios relacionados con el control óptimo de invernaderos han indicado que el enriquecimiento con CO₂ en climas cálidos, requiere un delicado balance entre la necesidad de ventilación y el deseo del enriquecimiento (Amir, 2005).

En invernaderos que no cuentan con sistemas de enriquecimiento, es muy importante tener en cuenta que llega un momento en que la concentración de CO₂ es inferior en el interior, que en el exterior del invernadero. A partir de este momento es cuando sería conveniente ventilar, ya que cambiaríamos aire con menos CO₂, por aire con más CO₂ (Wilkinson, 2000). No obstante, Hand (1984) mostró que en verano, la fotosíntesis puede reducir sustancialmente la concentración de CO₂ dentro del follaje del cultivo, comparado con la concentración fuera del invernadero, a pesar del constante suministro del gas por medio de ventilación.

2.2.5 Déficit de Presión de Vapor

La cantidad de agua que se transporta de la hoja a la atmósfera está regulada por el déficit de presión de vapor (VPD, por sus siglas en inglés) y gobernada por los estomas. La conductancia estomática es una medida de la transferencia de CO_2 y vapor de agua hacia dentro y fuera de la hoja vía estomas, respectivamente. Conductancia es usada en vez de resistencia, puesto que es directamente proporcional a la fotosíntesis y transpiración (Wilkinson, 2000).

La interacción entre temperatura y contenido de vapor en el aire y su efecto en el crecimiento, y calidad de los cultivos es difícil de determinar. El problema surge de la relación física entre temperatura y humedad. El efecto resultante de estas variables es referido como déficit de presión de vapor, que es usado en la mayoría de los casos para análisis de microclimas (Schmidt, 2004).

El déficit de presión de vapor es la fuerza impulsora para retirar el vapor de agua de una superficie, éste es la diferencia entre la presión del vapor de agua capaz de contener la atmósfera circundante (e_s) y la presión de vapor de agua en dicha superficie (e_a). A medida que ocurre la transpiración, el aire circundante se satura gradualmente y el proceso se vuelve cada vez más lento hasta detenerse completamente si el aire húmedo circundante no se transfiere a la atmósfera o, en otras palabras, no se retira de alrededor de la hoja. Si el proceso de transpiración se detiene, entonces lo hace también la difusión de moléculas de CO_2 hacia el interior de las hojas, afectando el proceso fotosintético de la planta (Boletín 56 FAO, 2006).

La presión de saturación de vapor puede ser calculada en función de la temperatura del aire, pues depende de ella. La relación entre ambas variables se expresa como:

$$e_s = 0.6108 * \exp\left[\frac{17.27 * T}{T + 237.3}\right]$$

donde:

e_s : es la presión de saturación de vapor a la temperatura del aire T [kPa]

T: es la temperatura del aire [°C]

$\exp[\dots]$: 2.7183 (base del logaritmo natural) elevado a la potencia [...]

No es posible medir directamente la presión real de vapor (e_a). La presión de vapor se deriva comúnmente de la humedad relativa o de la temperatura del punto de rocío. Al derivarlo de la humedad relativa, se calcula de la siguiente forma:

$$e_a = e_s * \frac{HR}{100}$$

Por lo tanto el déficit de presión de vapor queda de la siguiente forma:

$$VPD = e_s - e_a$$

2.3 Tecnología de Fitomonitorio

Los procesos de automatización en invernaderos están implementando tecnologías que están basadas en la respuesta de las plantas al ambiente en vez de monitorear el invernadero por completo (van Tuijl *et al.*, 2008). La tecnología de fitomonitorio es uno de los métodos que está atrayendo más y más la atención, pues por medio de ella se puede obtener información del crecimiento de la planta así como del flujo instantáneo de energía y masa (Schmidt, 2002.)

El fitomonitorio es la primera tecnología computarizada para observar en tiempo real aspectos del desarrollo de las plantas en el invernadero. Al introducir el sistema de fitomonitorio, se le permite al productor tener información esencial acerca de las

condiciones fisiológicas del cultivo. Esta tecnología combina (1) adquisición de datos basada en sensores específicos y (2) un software de procesamiento de información que permite tomar decisiones agronómicas. Así mismo, el uso de esta tecnología es muy acertado como una herramienta para hacer investigación (Ton *et al.*, 2001).

El monitoreo en tiempo real y continuo de la respuesta fisiológica de la planta a los cambios del ambiente también da información muy importante para controlar el ambiente -invernadero de forma precisa. Entre los procesos que se pueden medir gracias a la tecnología del fitomonitorio, se encuentran, por ejemplo, la fotosíntesis, respiración, transpiración, crecimiento de fruto, transporte de savia (Ton & Kopyt, 2003; Tantau, 2006; Roh, 2007).

Actualmente hay muy pocas ayudas disponibles para estimar la eficiencia fisiológica y económica del clima del invernadero, misma que está relacionada con los límites óptimos de las condiciones de temperatura y humedad relativa del aire. Pero al hacer uso de la tecnología de fitomonitorio, las condiciones climáticas pueden ser evaluadas con la ayuda de la información que la propia planta puede generar (Schmidt, 2005).

Dentro de la tecnología de fitomonitorio, uno de los procesos fisiológicos que demanda gran atención es la fotosíntesis. Debido a la gran importancia de ésta, en los últimos años se han desarrollado diferentes métodos de medición para lograr más conocimiento de este proceso fisiológico. Entre estos se encuentran: el método de acumulación de materia seca, métodos manométricos, métodos basados en el uso de sensores electroquímicos, método por ondas sonoras, técnicas basadas en la fluorescencia y los métodos basados en el intercambio de gases.

Para la medición de la fotosíntesis, el método de intercambio de CO_2 es el más usado para construir sistemas de fitomonitorio comerciales y experimentales. El procedimiento de este método consiste en aislar el espécimen dentro de una cámara cerrada para medir la concentración de gases, con la ayuda de sensores infrarrojos de análisis de gases (IRGA); después de unos minutos de que la cámara se cerró se obtienen los datos del cambio en la concentración de los gases, debido a la acción de la planta, de esta forma, la fotosíntesis de la planta puede ser medida con precisión (Millan, *et al.*, 2009).

La tecnología de fitomonitorio constituye una transición de la información de los sensores en las plantas hacia una tecnología de información sistematizada para el control del invernadero (Ton & Kopyt, 2002).

2.4 Modelación Matemática de cultivos

Los modelos matemáticos son herramientas muy poderosas para probar hipótesis, sintetizar conocimiento y entender sistemas complejos, así como comparar diferentes escenarios (Marcelis & Heuvelink, 2009).

Un modelo es definido como una representación matemática de un sistema, y la modelación es el proceso de desarrollo de esa representación. Un modelo de un cultivo es el conjunto de relaciones matemáticas que describen los cambios en las variables de estado como resultado de los diversos procesos que ocurren (Peart and Bruce, 1998).

La modelación de cultivos inició en los setentas con la elaboración de una visión integrada y dinámica de la fisiología de las plantas y con la generalización en el uso de computadoras en todos los ambientes científicos. El desarrollo fue rápido tan pronto los

modelos parecieron ser herramientas muy poderosas en el ámbito científico y de la ingeniería (Gary, 1999).

Los modelos de cultivos pueden ser usados para identificar las condiciones deseadas de crecimiento, explorar efectos de las condiciones de desarrollo relacionadas a la introducción de nuevas tecnologías, así como a la identificación de tratamientos que son particularmente importantes en un ambiente específico. Los modelos han sido usados en sistemas de apoyo para la toma de decisiones, control de clima y riego, así como para predicción y planeación de la producción (Marcelis & Heuvelink, 2009).

Modelos de simulación de cultivos son herramientas invaluableles para la optimización del microclima de los invernaderos, así como para tomar decisiones en técnicas de manejo a fin de incrementar los niveles de producción así como los beneficios económicos (Kim & Lieth, 2003).

Desde el momento en que la cantidad de radiación, la temperatura y humedad son alteradas por los propios invernaderos, el efecto de esas alteraciones en procesos fisiológicos relacionados al crecimiento de las plantas debe ser investigado por medio de modelación. Por ejemplo, la reducción de la radiación y por lo tanto de la temperatura de las hojas puede ser benéfico para la reducción de la transpiración, pero esto puede afectar la tasa de fotosíntesis y eventualmente el crecimiento del cultivo (Massacci, 2000).

En los últimos años se han diseñado diferentes regímenes dinámicos de temperatura para ahorrar energía en invernaderos. Dentro de esos regímenes la apertura de ventanas se plantea a temperaturas más elevadas que con los protocolos normales. Esto conduce a dos diferencias importantes: 1) la temperatura aumenta con la radiación y 2) es posible incrementar la concentración de CO₂ sin las pérdidas normales generadas

por la apertura de ventanas. De esta forma se crea un interesante problema de optimización del clima del invernadero, porque elevadas concentraciones de CO_2 se mantienen con poca o nula ventilación, situación que también resulta en la elevación de la temperatura al interior del invernadero. Para tomar esto en cuenta, en la optimización del clima del invernadero, es necesario el uso de modelos más fiables para predecir la fotosíntesis de los cultivos dentro diferentes rangos de temperatura y humedad (Körner, 2004), así como para generar procedimientos de control que no involucren la manipulación del invernadero por completo, sino sólo correcciones locales (Rojano *et al.*, 2008).

2.4.1 Modelos Mecanicistas de Fotosíntesis

Un gran número de modelos para describir la fotosíntesis han sido desarrollados. Estos incluyen modelos simples y modelos extremadamente complicados, modelos empíricos y modelos que son diseñados para ser lo más amplios en integración de parámetros (Pachepsky & Acock, 1996a).

Una gran variedad de técnicas matemáticas han sido usadas en esos modelos, básicamente fórmulas algebraicas combinadas con métodos de integración especiales. Esta variedad de técnicas se debe a que muchos modelos fueron creados para resolver diferentes problemas, desde la necesidad de proveer de un sub-modelo de fotosíntesis a un modelo general de productividad de cultivos (Gijzen, 1990), hasta la necesidad de modelos especializados para investigar la naturaleza de uno o más componentes en el proceso de la fotosíntesis (Pachepsky & Acock, 1996a).

Los tres modelos más populares de fotosíntesis foliar son los modelos de Acock (1991), Harley & Tenhunen (1991) y Evans & Farquhar (1991). Los tres modelos han

demostrado ser cuantitativamente adecuados para ajustar curvas de respuesta a la luz (Pachepsky & Acock, 1994b). El modelo de Acock, por ejemplo, tiene pocos parámetros y su fórmula empírica es simple, este modelo es suficiente para predicción de productividad. Los modelos de Harley y Farquhar al ser modelos de fotosíntesis más complicados pueden ser usados con propósitos de investigación, por ejemplo la descripción del ciclo de Calvin, la ruta de la foto-respiración o el transporte de electrones (Pachepsky & Acock, 1994a).

Los modelos mecanicistas de fotosíntesis foliar están basados en la integración de sub-modelos de fotosíntesis de hoja y de intercepción de radiación (Gijzen, 1988; Goudrian & Van Laar, 1994; Bailey *et al.*, 1997; Anten, 1997).

Los parámetros de estos modelos son, básicamente, constantes que se relacionan con la geometría del follaje y con diversas propiedades de las hojas. Uno de estos modelos que describe la tasa de fotosíntesis *del cultivo de tomate* fue desarrollado por Acock *et al.* (1978) (posteriormente modificado en 1991), la base de este modelo es la radiación solar así como la concentración de CO₂ (Bailey *et al.*, 1997). Este modelo está descrito por la siguiente ecuación:

$$P = \beta \left[\frac{\gamma c}{K} \ln \left(\frac{\alpha K I + (1 - \tau) \gamma c}{\alpha K I \exp(-KL) + (1 - \tau) \gamma c} \right) \right] - R$$

Donde $P (g m^{-2} h^{-1})$ es la tasa de fotosíntesis neta, $R (g m^{-2} h^{-1})$ es la tasa de respiración, $\alpha (g J^{-1})$ es la eficiencia del uso de la radiación por la hoja, K es el coeficiente de extinción del follaje, $I (W m^{-2})$ es la radiación fotosintéticamente activa a la punta del follaje (tomada como 0.47 de la radiación solar global), τ es el coeficiente de transmisión de las hojas, $\gamma (ms^{-1})$ es la conductancia de la hoja, L es el índice de

área foliar, c (gm^{-3}) es la concentración de CO_2 y β (3600) es el factor de conversión de horas a segundos.

Como uno de los principales módulos de los modelos de simulación de cultivos, el modelo de fotosíntesis debe ser amplio, abarcando todas las variables que pueden ser controladas y monitoreadas. Por ejemplo, el modelo de Farquhar, von Caemmerer y Berry (FvCB model) (Farquhar *et al.*, 1980) ha sido adoptado extensivamente en estudios de modelación ecológica y fisiológica, incluyendo estudios del efecto de altos niveles de CO_2 en la producción de plantas (Kim & Lieth, 2003; Ethier & Livingston, 2004).

La mayor ventaja del uso de este modelo radica en que, al ser un modelo bioquímico y mecanicista, es capaz de describir procesos que no podrían ser correctamente descritos por planteamientos empíricos. La desventaja del modelo radica en que requiere la calibración de un número muy extenso de parámetros (Kim & Lieth, 2003).

De la misma forma que el modelo de Farquhar, la mayoría de los modelos mecanicistas de fotosíntesis requieren un gran número de parámetros como entradas y éstos deben ser determinados básicamente por medio de mediciones directas. Tales mediciones son usualmente costosas, consumen demasiado tiempo y son destructivas (Anten, 1997). No obstante la exhaustiva determinación de los parámetros de los modelos, para su uso en otros ámbitos, muchas veces es necesario reajustar los valores de estos parámetros, haciendo a los modelos no tan fiables para su uso (Nederhoff & Vegter, 1994).

En muchos otros modelos publicados, las ecuaciones de Farquhar han sido aplicadas directamente al follaje de las plantas, asumiendo que éste último se comporta

como una “hoja grande”. Esta aproximación a hoja grande es aceptable para estimar la tendencia estacional de la fotosíntesis del follaje, pero es inadecuada para simular las variaciones diarias, cuando es comparada con mediciones provenientes de sistemas de intercambio de gases (Chen *et al.*, 1999). Para eliminar esos errores, se han propuesto modelos que consideran el follaje del cultivo como una sucesión de capas. En estos modelos, se integran por separado las fracciones de hojas bien iluminadas y las que están bajo sombra (de Pury & Farquhar, 1997); aunque también existen publicaciones en las que se reporta la medición directa de la tasa de fotosíntesis a plantas completas (Lootens & Vandecasteele, 1998).

Debido a la respuesta no lineal de la fotosíntesis de hojas a las condiciones meteorológicas (radiación, temperatura, humedad), existen considerables errores en el cálculo de la fotosíntesis si no se toma en cuenta la variabilidad diurna de estas variables (Chen *et al.*, 1999).

Para estudiar el efecto de elevadas concentraciones de CO₂ y de temperatura en la fotosíntesis de plantas, el modelo más conveniente es aquel que incluya una relación directa entre la fotosíntesis y los factores ambientales. Por lo tanto, es deseable determinar las dependencias de los parámetros de los modelos de acuerdo a las condiciones externas (Pachepsky & Acock, 1994b). Una forma de relacionar los parámetros ambientales con la actividad fotosintética se ha logrado al introducir metodologías de medición basadas en sistemas de intercambio de gas (Sciortino *et al.*, 2008).

2.4.2 Modelos de Caja Negra

Dentro de la optimización del clima del invernadero, la combinación de sistemas de control por separado para temperatura del aire, humedad relativa y concentración de CO₂ sigue siendo un problema (Schmidt, 2005).

La coordinación de controles automáticos individuales y los algoritmos predictivos son las principales propuestas para lograr un proceso de control climático más preciso en invernaderos. La coordinación de sistemas de control de temperatura y de humedad relativa por medio de calefacción y ventilación encuentran el problema de la respuesta en sentido opuesto de los controles. Para evitar esta problemática, nuevas propuestas de algoritmos de control están siendo usadas para optimizar el microclima de los invernaderos, principalmente por medio de métodos de inteligencia artificial (Arias *et al.*, Morimoto & Hashimoto, citados por Schmidt, 2005).

Por ejemplo, se han usado modelos de caja negra para encontrar modelos de temperatura al interior del invernadero que sean de fácil aplicación en sistemas de control de invernaderos, como los modelos ARX (López *et al.*, 2007), así como modelos de redes neuronales artificiales (ANN, por sus siglas en inglés) (Ferreira, 2002; Linker, 2004; Frausto, 2004; Tantau *et al.*, 2008).

También se han usado de redes neuronales artificiales (ANN, por sus siglas en inglés) en invernaderos experimentales para estimar ventilación de acuerdo a diferentes combinaciones de apertura de ventanas y condiciones ambientales. Otros autores han usado ANN para control óptimo de invernaderos y encontraron que los modelos de redes neuronales evitan la dificultad de encontrar modelos físicos que relacionen las tasas de ventilación con condiciones exteriores. Sin embargo, el uso de redes neuronales no sólo se ha realizado para ajuste de modelos a datos experimentales, sino también para

optimizar la operación de invernaderos, principalmente la manipulación de las variables temperatura y CO₂ (Seginer, Linker, citados por Salazar *et al.*, 2008), así como de la relación entre variables temperatura y humedad relativa (Salazar *et al.*, 2008; Chengwei & Fen, 2010).

Salazar *et al.*, (2010), encontró que con el uso de la tecnología de redes neuronales es posible hacer predicciones bastante exactas (con 5 y 10 minutos de anticipación) tanto de la temperatura al interior del invernadero, como de la fotosíntesis de plantas de tomate cultivadas al interior del mismo.

Las redes neuronales incluso se han aplicado en sistemas de detección de fallas en sistemas de control de invernaderos (Linker *et al.*, 2002).

Otros modelos de caja negra bastante exitosos en la predicción de la temperatura y humedad al interior del invernadero son los modelos neuro-difusos, que combinan las ventajas de las redes neuronales y de los sistemas difusos (Tien, Jang *et al.*, Babuska & Verbruggen, citados por López & Larragoiti, 2010).

3. MATERIALES Y MÉTODOS

3.1 Invernadero Experimental del Campus Amazcala de la Universidad Autónoma de Querétaro.

La investigación se desarrolló en un invernadero del Campus Experimental de la Universidad Autónoma de Querétaro ($20^{\circ} 42'$ Latitud Norte), tipo capilla con ventilación natural por medio de cortinas laterales en los cuatro lados, con cubierta de polietileno (Figura 3.1). Las dimensiones de éste son: 24 m largo x 9 m de ancho y 6 m de altura al caballete, con orientación Norte – Sur en el sentido de las canaletas. El sistema para el control de temperatura es muy sencillo, basado en apertura y cierre de las cortinas cuando las condiciones climáticas así lo requieren.



Figura 3.1) Invernaderos experimentales del Campus Amazcala de la Universidad Autónoma de Querétaro.

El experimento consistió en monitorear el intercambio de CO_2 de las hojas de plantas de tomate bien desarrolladas (*Lycopersicon esculentum*), cultivadas en el invernadero por medio del Fitomonitor PTM-48M (Daletown Company Ltd), automático de cuatro cámaras, con sistema de tipo abierto. En la Figura 3.2 se muestran los sensores empleados durante la investigación.

Las variables registradas por el Fitomonitor PTM-48M cada 30 minutos fueron: CO_2 de referencia (ppm), CO_2 de la cámara durante la medición (ppm), flujo de aire al sistema (lpm), fotosíntesis ($\mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$), humedad absoluta del aire (gm^{-3}), tasa de transpiración ($\text{mgH}_2\text{O m}^{-2}\text{s}^{-1}$), temperatura ($^{\circ}\text{C}$) y humedad relativa (%) del aire, presión atmosférica (mbar) y déficit de presión de vapor (kPa), todas a nivel de hoja. Los sensores se colocaron a media profundidad del dosel, así como en la parte superior del mismo, en hojas con ancho mayor a 5cm, excluyendo hojas viejas.

Se instaló también un sensor de Radiación Fotosintéticamente Activa, Watch Dog Model 450 (Spectrum Technologies Inc.); este sensor devuelve las mediciones cada 5 minutos en unidades cuánticas, ($\mu\text{mol Fotones m}^{-2}\text{s}^{-1}$).

Las mediciones se realizaron del 3 de Noviembre (30 días después del trasplante) al 27 de diciembre del 2009.



Figura 3.2) Sensores instalados en el experimento. Izquierda, 2 cámaras de monitoreo y sensor ventilado para temperatura y humedad relativa del PTM-48M. Derecha, sensor de radiación PAR.

3.2 Invernaderos Experimentales de la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín.

Este estudio fue desarrollado en dos invernaderos experimentales de vidrio, tipo venlo, ubicados en las instalaciones de la Facultad de Horticultura de la Universidad Humboldt de Berlín, Alemania (52° 28' Latitud Norte); las dimensiones de cada cabina son, 9.6 m de ancho por 12 m de largo, 4.1 m de altura hasta el caballete; el área de cada cabina es de 115 m². La proporción de área de ventanas (cenitales) comparada con la superficie que cubre cada cabina es de 50% (Figura 3.3).

El experimento consistió en el registro de variables climáticas y de respuesta de plantas de tomate (*Lycopersicon esculentum*) cultivadas bajo invernadero. El proceso de toma de datos se llevó a cabo, del 19 de Agosto al 25 de Noviembre de 2009. Se tuvieron dos cabinas diferentes para el experimento: a) cabina 5, aplicando el Sistema de Humidificación del Aire (Des-Fog, por sus siglas en inglés); b) cabina 2, controlando la temperatura con un Sistema Convencional de apertura y cierre de ventanas, sin emplear el sistema Des-Fog.

El Sistema Des-Fog consiste en la aplicación de agua en forma de neblina al invernadero, con la finalidad de reducir la temperatura, además de incrementar el contenido de humedad del aire que rodea el dosel del cultivo, mejorando así las condiciones ambientales para el crecimiento y desarrollo de las plantas. La cabina número 5 se equipó con 5 difusores para la nebulización; éstos trabajan a una presión de 120 bar, generando partículas de agua de 10 nm, por lo que no existe condensación.



Figura 3.3) Invernaderos experimentales de la Facultad de Horticultura de la Universidad Humboldt de Berlín.

En ambas cabinas se tuvieron 128 plantas de tomate, usando como sustrato lana de roca. Además se usó un sistema de enriquecimiento con CO₂ en el que de 5 am a 11 am se eleva la concentración a 900 *ppm* y de 11 am a 5:15 pm se mantiene en 700 *ppm*. El sistema Des-Fog inicia cuando la temperatura se eleva a más de 23°C y se detiene cuando la humedad relativa está en el límite del 80%. En el Sistema Convencional la apertura de ventanas inicia a los 23°C.

Se empleó el Fitomonitor PTM-48M (Daletown Company Ltd.), automático de cuatro cámaras, con sistema de tipo abierto para el monitoreo del intercambio de CO₂ de las hojas. Las cámaras de monitoreo se distribuyeron entre el cultivo con el fin de tener mediciones uniformes.

Las variables registradas por el Fitomonitor PTM-48M (Figura 3.4) cada 15 min fueron las mismas que se registraron para el experimento de Querétaro (sección 3.1) debido a que es el mismo tipo de sistema de Fitomonitorio. Sin embargo, el equipo empleado en Alemania contó con un sensor de radiación global con unidades radiométricas en Wm⁻².

También se instalaron en cada cabina cinco sensores PTF-30 (Positronik Company) con aspiración, para medir cada 5 minutos las condiciones de temperatura ($^{\circ}\text{C}$), humedad relativa (%) y concentración de dióxido de carbono del aire dentro de las cabinas (ppm).



Figura 3.4) Sensores empleados para monitorear las condiciones del cultivo. Izquierda, PTM-48M; derecha, PTF-30.

3.3 Fórmula para calcular la Fotosíntesis Foliar.

El Fitomonitor PTM-48M calcula el intercambio de CO_2 que realizan las hojas de tomate en cada una de sus cuatro cámaras y extrapola este valor para reportar la tasa de fotosíntesis a 1m^2 de hojas. Sin embargo, para realizar los cálculos emplea la salida del sensor de temperatura con que cuenta el equipo y considera el valor de esta variable como constante para las 4 cámaras en un tiempo determinado.

El problema de esta forma para calcular la fotosíntesis radica en que, debido a lo costoso del equipo de fitomonitoreo, fue necesario repartir las cuatro cámaras en las dos cabinas, Sistema Convencional y Sistema Des-Fog, para el caso de los invernaderos experimentales de la Universidad Humboldt de Berlín; y tratamiento 1 y 2, en el caso del invernadero experimental de la Universidad Autónoma de Querétaro. Debido a

problemas con el sensor de temperatura y humedad en el tratamiento 2, no se empleó la información de las cámaras 3 y 4 del fitomonitor. Consecuentemente, al ser en cada caso dos invernaderos totalmente independientes con condiciones de la variable temperatura distintas, se incurriría en un error si se considerara que el valor reportado por el equipo de fitomonitorio para la variable fotosíntesis es correcto para las condiciones del microclima en que se instalaron cada una de las cámaras.

Debido a lo anterior, durante esta investigación se adaptó una ecuación para calcular la tasa de fotosíntesis foliar (Ecuación 1), desarrollada por el Equipo de Investigación en Tecnología de Fitomonitorio y Estrategias de Fitocontrol de la Universidad Humboldt de Berlín.

$$mGWC_{O_2} = \frac{D * DiffCO_2 * \rho_{CO_2}}{10^3 * BFK\ddot{U}V * M_{CO_2} * 3600} * 10^6 \quad (1)$$

Donde:

$mGWC_{O_2}$ = Tasa de fotosíntesis ($\mu\text{molCO}_2 \text{ m}^{-2}\text{s}^{-1}$)

D = Flujo de aire de la cámara al sistema (m^3h^{-1})

$DiffCO_2$ = Diferencia en la concentración de CO_2 entre referencia y la cámara (ppm)

ρ_{CO_2} = Densidad del CO_2 (1.98 kg m^{-3})

$BFK\ddot{U}V$ = Área de la cámara (m^2)

M_{CO_2} = Masa molar del CO_2 (44.01 g mol^{-1})

La aportación de este trabajo radicó en considerar la densidad del gas CO_2 , no como una constante, sino como una variable dinámica, es decir, que su valor depende de la presión atmosférica y de la temperatura ambiental con respecto al tiempo.

Para realizar este cambio se recurrió a la Ley general de gases ideales (Cengel, 2005), aplicando los siguientes cambios:

$$PV = mRT \quad (2)$$

$$\frac{V}{m} = \frac{RT}{P} \quad (3)$$

$$v = \frac{RT}{P} \quad (4)$$

$$\frac{1}{v} = \rho = \frac{P}{RT} \quad (5)$$

De la Ecuación 2, se obtiene la expresión para calcular el volumen específico del un gas ideal (Ecuaciones 3 y 4); posteriormente, al aplicar el inverso a (4), se obtiene la ecuación con que se calcula la densidad del gas a partir de los valores de presión y temperatura del mismo, así como de la constante específica para gases ideales, R. Finalmente, la expresión (5) se sustituye en la ecuación (1).

Con la nueva ecuación es posible calcular la tasa de fotosíntesis real de cada una de las cuatro cámaras para condiciones distintas de temperatura, pasando así de un 8-10% de error en las mediciones, comparadas con el valor reportado por el fitomonitor, a menos de 0.8%; es decir, la ecuación modificada es 10 veces más precisa que la anterior.

La nueva ecuación se muestra a continuación:

$$mGWCO_2 = \frac{D * DiffCO_2 * P}{29.9322044 * BFK\ddot{U}V * T} \quad (6)$$

Donde:

$$mGWCO_2 = \text{Tasa de fotosíntesis } (\mu\text{molCO}_2 \text{ m}^{-2}\text{s}^{-1})$$

D = Flujo de aire de la cámara al sistema ($m^3 h^{-1}$)

$DiffCO_2$ = Diferencia en la concentración de CO_2 entre referencia y la cámara (ppm)

P = Presión atmosférica (kPa)

$BFKÜV$ = Área de la cámara (m^2)

T = Temperatura del aire ($^{\circ}K$)

Nota:

El valor de P puede ser sustituido por la presión atmosférica media durante el año, al interior del invernadero. Por lo tanto, P puede ser tratada como una constante en la fórmula. El error generado cuando se hace este cambio a través de 22400 mediciones se eleva a 1.5%. La constante 29.9322044^{-1} es un factor que proviene de:

$$\frac{10^6}{10^3 * MCO_2 * 3600 * R} = \frac{1}{29.9322044}$$

Donde:

MCO_2 = Masa molar del gas CO_2 : $44.01(gmol^{-1})$

R = Constante específica para gases ideales: $0.188923(kJ * kg^{-1}K^{-1})$

10^6 = Factor para transformar el resultado a unidades en: ($\mu molCO_2$)

10^3 = Factor para convertir las unidades de $kmol$ a mol

3600 = Factor de conversión para pasar de horas a segundos.

Posteriormente, se realizó un análisis dimensional para convertir las salidas de los sensores del Fitomonitor PTM-48M a las unidades requeridas por la fórmula de la fotosíntesis; una vez hecho esto, se recalcularon los vectores de Fotosíntesis, ya corregidos con las condiciones de temperatura correctas, para cada una de las cámaras de los experimentos.

3.4 Pre-procesamiento de datos.

Las mediciones realizadas en Querétaro se hicieron cada 30 min con el equipo de fitomonitorio, mientras que el registro del sensor de radiación se realizaban cada 5 minutos; por lo tanto, de acuerdo con Salazar *et al.* (2010), fue necesario hacer una interpolación lineal para los datos del fitomonitor a fin de generar dos puntos extras, teniendo así datos de todas las variables del equipo de Fitomonitorio cada 10 min. Los datos del sensor adicional se pasaron de 5 min a 10 min por eliminación.

Se empleó el mismo tipo de interpolación para los datos de Berlín, para pasar las mediciones del PTM-48M de 15 min a 5 min y de esta forma hacerlas coincidir con los datos climáticos del PTF-30, que se encuentran en ese mismo rango de tiempo.

Después de cambiar los vectores con los datos de fotosíntesis corregidos por la fórmula de la fotosíntesis y de haber realizado las interpolaciones, se procedió a conjuntar todas las variables medidas por el sistema de fitomonitorio con los datos medidos por los sensores instalados adicionalmente, para generar las matrices de información, tanto para el experimento de Querétaro como para el de Berlín.

Para lograr lo anterior, se eliminó la información en la que no existían registros para todos los sensores. Esta falta de información se produjo debido a la diferencia entre los tiempos de muestreo del fitomonitor y de los sensores adicionales, así como a la capacidad de almacenamiento de cada tipo de instrumento, pues en ocasiones ésta llegaba al límite dejando de guardar las mediciones.

Con las matrices ya creadas se procedió a aplicar una serie de filtros a los datos, con la finalidad de eliminar los ruidos de los sensores, excluyendo también

comportamientos no deseados para el proceso de búsqueda del mejor modelo de fotosíntesis, objetivo de esta investigación.

El primer filtro aplicado a las matrices de datos, tanto de Querétaro como de Berlín fue el propuesto por Savitzky & Golay (1964), por medio de Matlab. Los coeficientes del filtro quedaron de la siguiente forma: para las variables fotosíntesis y radiación se empleó una función de segundo orden y 25 datos de tendencia de curva (Figura 3.5); para las variables temperatura, humedad relativa, concentración de CO_2 y déficit de presión de vapor, se empleo el mismo orden y 7 mediciones adelante y atrás del valor estimado. El tiempo de retrasos y adelantos entre las variables que se filtran dependen del tipo de cada una, así como al desfaseamiento, hacia la derecha o izquierda, de los datos nuevos con respecto de los originales por acción de la tendencia que sigue el filtro. En la Figura 3.6, se observa el comportamiento del filtro sobre las tendencias de curva para diferentes órdenes y número de retrasos y adelantos de la variable radiación.




Figura 3.5) Filtro Savitzky-Golay aplicado a datos de radiación.




Figura 3.6) Diferentes coeficientes Savitzky-Golay para filtrar radiación. El tipo de filtro depende del comportamiento de la variable medida.

De la figura anterior puede verse que filtros de mayor orden o con menor número de retrasos y adelantos, ajustan mucho mejor los datos originales, sin embargo, para los fines de esta investigación, el mejor desempeño lo presentan los filtros descritos líneas arriba, pues eliminan el ruido de los sensores sin perder la tendencia de la variable en cuestión.

Además del filtro Savitzky-Golay, se eliminaron también los datos del fitomonitor en que el intercambio de CO_2 presenta valores negativos, correspondiendo éstos al proceso fisiológico de la respiración durante las horas sin radiación; así mismo, se convirtieron a ceros los registros en que la radiación durante la noche es diferente de ese valor, debido a la alta precisión de los sensores, que son capaces de captar factores externos. Finalmente, se eliminaron las colas de las curvas de radiación y fotosíntesis

que seguían una tendencia negativa debido a la aplicación del filtro Savitzky G. como ya se explicó, ninguna de estas variables puede tener valores por debajo de cero. En la Figura 3.7 se muestran los cambios consecutivos después de aplicar los filtros descritos.




Figura 3.7) Filtros aplicados a los datos de fotosíntesis. A) Valores originales del PTM-48M; B) Sin respiración; C) En círculos se muestran las tendencias negativas después de aplicar el filtro Savitzky Golay; D) Curvas finales de fotosíntesis.

3.5 Pre-procesamiento de datos para la Identificación de Sistemas.

La identificación de Sistemas es el arte y la ciencia de construir modelos matemáticos de sistemas dinámicos a partir de la observación de datos de entrada y salida. Identificación de Sistemas es un tema muy amplio, con diferentes técnicas que dependen del tipo de modelo a ser estimado: lineal, no lineal, híbrido, no paramétrico, etc. (Ljung, 2008).

Dentro de los modelos lineales de caja negra, derivados de la teoría de Identificación de Sistemas, se encuentra el modelo Auto-regresivo con Variables Exógenas (ARX).

En tiempo discreto, la estructura del ARX es una ecuación en diferencias con la siguiente forma:

$$\begin{aligned} y(t) + a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) \\ = b_1 u(t-n_k) + \dots + b_{n_b} u(t-n_k-n_b+1) + e_t \end{aligned} \quad (7)$$

Donde, $y(t)$ representa la salida en el tiempo t ; $u(t)$ representa las entradas en el tiempo t ; n_a es el número de polos, también conocido como el número de pasos de tiempo de la salida en el pasado; n_b es el número de parámetros (igual al número de ceros más uno), es decir, el número de retrasos de la variable de entrada; n_k es el retardo de la entrada $u(t)$ con respecto de la salida $y(t)$; $e(t)$ es el ruido blanco asociado con la variable de salida (López *et al.*, 2007).

Un modelo ARX de múltiples entradas y múltiples salidas (MIMO) está descrito por la ecuación:

$$A(q)y(t) = \sum_{i=1}^{nu} B_i(q)u_i(t-nk_i) + e(t) \quad (8)$$

Para un sistema con nu entradas y ny salidas, $A(q)$ es una matriz $ny \times ny$. Los elementos de $A(q)$ son polinomios en el operador de retraso $q^{-1}y(t) = y(t-1)$

$$A(q) = I_{ny} + A_1 q^{-1} + \dots + A_{n_a} q^{-n_a} \quad (9)$$

En forma de matriz, $A(q)$ se representa como:

$$A(q) = \begin{pmatrix} a_{11}(q) & a_{12}(q) & \dots & a_{1ny}(q) \\ a_{21}(q) & a_{22}(q) & \dots & a_{2ny}(q) \\ \dots & \dots & \dots & \dots \\ a_{ny1}(q) & a_{ny2}(q) & \dots & a_{nyny}(q) \end{pmatrix}$$

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

$$a_{kj}(q) = \delta_{kj} + a_{kj}^1 q^{-1} + \dots + a_{kj}^{na_{kj}} q^{-na_{kj}} \quad (10)$$

δ_{kj} representa la Kronecker delta, que es igual a 1 para $k = j$ e igual a 0 cuando $k \neq j$. Este polinomio describe cómo los valores pasados de la salida j^{th} son afectados por los valores de la k^{th} salida. El renglón i^{th} de $A(q)$ representa la contribución de los valores de salidas pasadas en la predicción del valor actual de la i^{th} salida.

$B(q)$ es una matriz $ny \times nu$. Los elementos de $B(q)$ son polinomios en el operador de retraso q^{-1} :

$$B(q) = B_0 + B_1 q^{-1} + \dots + B_{nb} q^{-nb} \quad (11)$$

En forma de matriz, $B(q)$ se representa como:

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

Donde los elementos b_{kj} son polinomios en el operador q^{-1}

$$b_{kj}(q) = a_{kj}^1 q^{nb_{kj}} + \dots + a_{kj}^{nk_{kj}} q^{-nb_{kj}+1} \quad (12)$$

nk_{kj} es el retraso de la j^{th} entrada a la k^{th} salida. $B(q)$, representa la contribución de las entradas en la predicción de todos los valores de las salidas (Ljung, 2007).

Para generar el modelo ARX, es entonces necesario determinar los coeficientes de las matrices $A(q)$ y $B(q)$, así como el orden del modelo. En general, el orden del modelo está relacionado con el número de polos, ceros y retrasos de la variable respuesta, es decir, n_a, n_b y n_k .

En esta investigación n_u se formó con cinco variables de entrada, mientras que n_y con una sola salida: la tasa de fotosíntesis [$\mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$]. Por lo tanto se trata de un sistema de múltiples entradas y una salida, es decir, un sistema MISO (Múltiples entradas y una salida).

$$n_u = \begin{pmatrix} 1. \text{Radiación PAR} \dots \dots \dots [Wm^{-2}] \\ 2. \text{Temperatura} \dots \dots \dots [^{\circ}C] \\ 3. \text{Humedad Relativa} \dots \dots \dots [\%] \\ 4. \text{Déficit de Presión de Vapor} \dots [kPa] \\ 5. \text{Nivel de CO}_2 \dots \dots \dots [ppm] \end{pmatrix}$$

Para implementar el sistema de búsqueda del mejor modelo ARX para predecir la tasa de fotosíntesis al interior del invernadero dado n_u , se generó una estructura de datos formada por la variable de salida, las variables de entrada así como el tiempo de muestreo. El tiempo de simulación es diferente entre los datos registrados en Querétaro (0.1666) y los registrados en Berlín (0.0833), pues depende del tiempo de adquisición de los datos, 10 minutos o 5 minutos, respectivamente.

La estructura de datos es necesaria para que el software Matlab, por medio de la herramienta de Identificación de Sistemas (System Identification Toolbox) pueda reconocer los datos de los experimentos, estimar los modelos y realizar el proceso de validación de los mismos.

Para determinar los valores óptimos de los parámetros n_a, n_b y n_k , se empleó como criterio de ajuste, el error final de predicción de Akaike (FPE) así como el criterio de Información de Akaike (AIC). Estos criterios emplean una función de pérdida mínima en combinación con un número mínimo de parámetros estimados (López *et al.*, 2007; Ljung, 2007), donde V es la función de pérdida, típicamente un ajuste cuadrático de la estructura; d es el número de parámetros estimados y, N es el número de datos.

$$FPE = \left(\frac{1 + \frac{d}{N}}{1 - \frac{d}{N}} \right) V \quad (13)$$

$$AIC = \log \left(V \left(1 + 2 \frac{d}{N} \right) \right) \quad (14)$$

Se evaluaron los subconjuntos de datos 80%:20% y 60%:40% para estimación y validación de los modelos, respectivamente. De acuerdo al número de entradas (5) y al orden de los modelos evaluados (10), para cada subconjunto se evaluaron 10^{11} modelos. pues existe una variable de salida, 5 variables de entrada y 5 variables de retraso.

Para evaluar la calidad predictiva del modelo, se empleó el nivel de juste (%) entre las tasa de fotosíntesis simuladas y las medidas. También se empleó Método de Validación Cruzada (Ljung, 2007) para verificar cuál es el comportamiento del mejor modelo obtenido con respecto de la prueba de Residuales.

Con la misma estructura de datos generada para buscar el mejor modelo ARX, y con ayuda del System Identification Toolbox, se indagó también en los siguientes modelos de caja negra: Modelo Auto-regresivo con Promedio Móvil y Entradas Exógenas (ARMAX), Box-Jenkins (BJ), Error de la salida (OE), incluso, en el modelo ARX no lineal.

3.6 Modelo Mecanicista para Fotosíntesis Foliar.

De acuerdo al Modelo Mecanicista de Goudriaan (Goudriaan & Van Laar, 1994), la tasa de asimilación instantánea de CO₂ por las hojas necesita calcular por un lado, la duración astronómica del día, las características de la radiación diurna tal como la integral diaria del seno de la elevación solar y la constante solar. A partir de esa información, es posible desarrollar una integración Gausiana sobre la profundidad del follaje y calcular la tasa de fotosíntesis, que para este modelo es una función de la respuesta de las hojas a la radiación solar a través del tiempo.

El Modelo Mecanicista de Goudriaan es la base para el cálculo de la cantidad de CO₂ que fija el cultivo por unidad de tiempo en el Modelo SUCROS (Simple and Universal Crop Simulator, Goudriaan & Van Laar, 1994). En seguida se presentan las ecuaciones necesarias para la integración de la tasa de fotosíntesis instantánea del cultivo.

La declinación solar como una función del día del año se calcula a partir del día Juliano que se requiere evaluar (DIA).

$$DEC = -\text{asin}(\sin(23.45 * \text{RAD}) * \cos(2 * \pi * (\text{DIA} + 10)/365)) \quad (15)$$

El factor para convertir grados a radianes:

$$\text{RAD} = \frac{\pi}{180} \quad (16)$$

El numero 23.45 representa la latitud de los trópicos, o equivalente al plano formado por el movimiento de la tierra alrededor del sol. La constante 10 se emplea para

compensar el día en que la tierra se encuentra más alejada del sol que es el 21 de diciembre, no el 31 de ese mes.

Las variables $Sinld$, $Cosld$ y AOB son variables intermedias en el proceso de cálculo y dependen de la latitud del lugar de experimentación, que debe encontrarse entre los -67° y 67° de latitud.

$$Sinld = \sin(RAD * Latt) * \sin(DEC) \quad (17)$$

$$Cosld = \cos(RAD * Latt) * \cos(DEC) \quad (18)$$

$$AOB = Sinld / Cosld \quad (19)$$

La longitud del día se calcula a partir del valor AOB anterior:

$$Dayl = 12 * \left[1 + \left(2 * \sin \frac{AOB}{\pi} \right) \right] \quad (20)$$

La radiación global proveniente del sol (entre 350-2000 nm de longitud de onda) en la superficie de la tierra es el producto de la radiación incidente fuera de la atmósfera y de la transmisibilidad atmosférica, que es muy dependiente del grado de nubosidad en un punto determinado. La radiación extraterrestre es proporcional al seno de la altura del sol y de la constante solar ($\approx 1370 \text{ } Wm^{-2}$); además la ruta de la tierra a través del sol es una elipse excéntrica, por lo tanto al corregir ese fenómeno, la radiación global incidente para un día cualquiera, es decir, la constante solar (Sc), es:

$$Sc = 1370 * (1 + 0.033 * \cos(2 * \pi * DIA / 365)) \quad (21)$$

Para una hora determinada a lo largo del día, el seno de la elevación solar se calcula de la siguiente forma:

$$\text{Sinb} = \max(0, \text{Sinld} + \text{Cosld} * \cos(2 * \pi * (\text{Hora} + 12)/24.0)) \quad (22)$$

La integral de la elevación solar sobre un día es:

$$\text{DSinb} = 3600 * (\text{Dayl} * \text{Sinld} + 24 * \text{Cosld} * \frac{\sqrt{(1-\text{AOB})*\text{AOB}}}{\pi}) \quad (23)$$

Con lo que la radiación disponible se describe así:

$$\text{AvRad} = \text{Atmtr} * \text{Sc} * \text{Sinb} \quad (24)$$

Para calcular la fracción de la Radiación difusa a partir de la transmisibilidad atmosférica, se emplean las siguientes relaciones:

$$\text{Frdf} = 1.47 - 1.66 * \text{Atmtr} \quad (25)$$

cuando, $(\text{Atmtr} \leq 0.35) \& (\text{Atmtr} > 0.22)$

$$\text{Frdf} = 1 - 6.4 * (\text{Atmtr} - 0.22)^2 \quad (26)$$

de lo contrario,

si $(\text{Atmtr} \leq 0.22)$

$$\text{Frdf} = 1$$

$$\text{Frdf} = \max(\text{Frdf}, 0.15 + 0.85 * (1 - e^{(-0.1/\max(0.01, \text{Sinb}))})) \quad (27)$$

Finalmente, la radiación fotosintéticamente activa (PAR) difusa (Pardf) y la PAR directa (Pardr) se obtienen con las siguientes relaciones, ambas en unidades de Wm^{-2} :

$$\text{Par} = 0.5 * \text{AvRad} \quad (28)$$

$$\text{Pardf} = \min(\text{Par}, \text{Sinb} * \text{Frdf} * \text{Atmtr} * 0.5 * \text{Sc}) \quad (29)$$

$$\text{Pardr} = \text{Par} - \text{Pardf} \quad (30)$$

Una vez calculada la cantidad y tipo de radiación fotosintéticamente activa incidente en el lugar de estudio, es posible realizar la integración Gausiana de cinco puntos (Goudriaan & Van Laar, 1994) para conocer la tasa de fotosíntesis instantánea de las hojas de las plantas de tomate de los experimentos. Para esto es necesario conocer los valores de los siguientes parámetros: Coeficiente de Dispersión de las Hojas para PAR , **SCP** (adimensional); Coeficiente de Extinción de la Radiación, **KDF** (adimensional); Eficiencia del Uso de la Radiación, **EFF** [$\text{mgCO}_2\text{J}^{-1}$]; la tasa máxima de asimilación de las hojas, **AMAX** [$\text{mgCO}_2\text{m}^{-2}\text{s}^{-1}$]; así como el Índice de Área Foliar, **LAI** [$\frac{\text{m}^2_{\text{hoja}}}{\text{m}^2_{\text{suelo}}}$].

La integración para este modelo se realiza por medio del método de 5 puntos de Gauss, con la ayuda del programa Matlab. Los pesos para estos puntos se muestran enseguida:

$$IGauss = 5$$

$$DATA XGAUSS = (0.0469101 \quad 0.2307534 \quad 0.5 \quad 0.7692465 \quad 0.9530899)$$

$$DATA WGAUSS = (0.1184635 \quad 0.2393144 \quad 0.284444 \quad 0.2393144 \quad 0.1184635)$$

La reflexión de hojas horizontales (Refh) y esféricas (Refs) se obtiene con estas relaciones:

$$Sqv = \sqrt{(1 - SCP)} \quad (31)$$

$$Refh = (1 - Sqv)/(1 + Sqv) \quad (32)$$

$$Refs = Refh * 2/(1 + 1.6 * Sinb) \quad (33)$$

El coeficiente de extinción para radiación directa y flujo total directo:

$$\text{Clustf} = \text{KDF} / (0.8 * \text{Sqv}) \quad (34)$$

$$\text{Kbl} = (0.5 / \max(0.01, \text{Sinb})) * \text{Clustf} \quad (35)$$

$$\text{Kdrt} = \text{Kbl} * \text{Sqv} \quad (36)$$

Para seleccionar la profundidad del follaje:

$$\text{Fgros} = 0.0, \text{Iabs} = 0.0$$

La asignación de valores para i se realiza así: i = 1: IGauss

$$\text{Laic} = \text{LAI} * \text{xGauss}(i) \quad (37)$$

Flujos de absorción por unidad de área foliar: flujo difuso, flujo total directo, componente directo del flujo directo:

$$\text{Visdf} = (1 - \text{Refh}) * \text{Pardf} * \text{KDF} * e^{(-\text{KDF} * \text{Laic})} \quad (38)$$

$$\text{Vist} = (1 - \text{Refs}) * \text{Pardr} * \text{Kdrt} * e^{(-\text{Kdrt} * \text{Laic})} \quad (39)$$

$$\text{Visd} = (1 - \text{SCP}) * \text{Pardr} * \text{Kbl} * e^{(-\text{Kbl} * \text{Laic})} \quad (40)$$

Flujo de absorción $[Jm_{hoja}^{-2} s^{-1}]$ para hojas sombreadas y asimilación para hojas sombreadas:

$$\text{Visshd} = \text{Visdf} + \text{Vist} - \text{Visd} \quad (41)$$

$$\text{Fgrsh} = \text{AMAX} * (1 - e^{(-\text{Visshd} * \frac{\text{EFF}}{\text{AMAX}})}) \quad (42)$$

Flujo de absorción de luz para las hojas perpendiculares al rayo de luz y asimilación de área iluminada por el sol:

$$\text{Vispp} = (1 - \text{SCP}) * \text{Pardr} / \max(0.01, \text{Sinb}) \quad (43)$$

$$\text{Fgrsun} = 0$$

$$\text{Iabsun} = 0$$

La asignación de valores para j se realiza así: j = 1: IGauss

$$Vissun = Visshd + Vispp * xGauss(j) \quad (44)$$

$$Fgrs = AMAX * \left[1 - e^{\left(-Vissun * \frac{EFF}{AMAX} \right)} \right] \quad (45)$$

$$Fgrsun = Fgrsun + Fgrs * wGauss(j) \quad (46)$$

$$Iabsun = Iabsun + Vissun * wGauss(j) \quad (47)$$

Fracción de área iluminada por el sol ($Fslla$) y asimilación local (Fgl):

$$Fslla = Clustf * e^{(-Kbl * Laic)} \quad (48)$$

$$Fgl = Fslla * Fgrsun + (1 - Fslla) * Fgrsh \quad (49)$$

$$Iabsl = Fslla * Iabsun + (1 - Fslla) * Visshd \quad (50)$$

Integración de la tasa de asimilación local para asimilación del follaje ($Fgros$):

$$Fgros = Fgros + Fgl * wGauss(i) \quad (51)$$

$$Iabs = Iabs + Iabsl * wGauss(i) \quad (52)$$

Finalmente, con las relaciones anteriores es posible integrar la Asimilación Instantánea de CO₂ por el follaje, ecuación 53, así como la Radiación Teórica Absorbida por el Dosel, ecuación 54:

$$Fgros = Fgros * LAI \quad (53)$$

$$ParAbs = Iabs * LAI \quad (54)$$

Se empleó el programa Matlab para calcular la cantidad y tipo de la radiación, tanto del sitio experimental de la Universidad Autónoma de Querétaro, como de la Universidad Humboldt de Berlín; también se programaron las ecuaciones para realizar la integración Gaussiana de la tasa de asimilación instantánea de CO₂. Ambos programas

se conjuntaron en un programa de Matlab Simulink, con el cual se realizaron las simulaciones del Modelo Mecanicista de Goudriaan. La solución para la Simulación del modelo fue por medio del Método de Euler, con tamaño de paso fijo de una hora.

Los parámetros SCP, KDF, EFF y la Transmisibilidad Atmosférica (ATMTR) fueron calibrados para cada conjunto de datos, tanto para Querétaro como para Berlín. Las calibraciones se realizaron por medio del método de mínimos cuadrados no lineales, para un día y para 5 días Julianos.

Para comparar la calidad predictiva del modelo mecanicista, una vez calibrado, contra las mediciones, se emplearon las estadísticas de ajuste (%), cuadrado medio del error (MSE) y la raíz del cuadrado medio del error (RMSE).

3.7 Redes Neuronales.

Las Redes Neuronales Artificiales (Artificial Neural Network, ANN, por sus siglas en inglés) son modelos de caja-negra, una forma de inteligencia artificial que “aprende” al procesar datos en patrones a través de su arquitectura interna y tienen la capacidad de modelar variables altamente no lineales (Salazar *et al.*, 2008).

Una red multicapa de perceptrones es la arquitectura más usada en una ANN; típicamente, tiene tres capas, consistentes en una capa de entrada, una capa oculta y una capa de salida. Cada capa está formada por nodos individuales y éstos se encuentran interconectados a través de las capas por funciones de transferencia no lineales, expresadas en términos de nodos de variables de entrada y conexiones por medio de pesos (Salazar *et al.*, 2008).

Cada capa tiene una matriz de pesos $\mathbf{W}$, un vector de sesgos $\mathbf{b}$, así como un vector de salidas $\mathbf{a}$. En la Figura 3.8 se muestra una red neuronal de 3 capas, que tiene R^1 entradas, S^1 neuronas en la primera capa, S^2 neuronas en la segunda capa, etc. Es común que se tenga diferente número de neuronas para diferentes capas.

Se puede notar que las salidas de cada capa intermedia, son la entrada de la siguiente capa. Por lo tanto, la capa 2 puede ser analizada como una red de una capa con S^1 entradas, S^2 neuronas, y $S^2 \times S^1$ matriz de pesos W^2 . La entrada de la capa 2 es a^1 ; la salida es a^2 .

Las capas de una Red Multicapa juegan diferentes roles. La capa que produce las salidas de la red se llama capa de salida (*output layer*). El resto de ellas son nombradas capas ocultas (*hidden layers*). La red mostrada en la Figura 3.8 tiene una red de salida (capa 3) y dos capas ocultas (capa 1 y 2).




Figura 3.8) Esquema de una Red Neuronal Multicapa.

Las salidas para las capas 1, 2 y 3 pueden describirse de la siguiente forma:

$$a^1 = f^1(IW^{1,1}p + b^1) \quad (55)$$

$$a^2 = f^2(LW^{2,1}a^1 + b^2) \quad (56)$$

$$a^3 = f^3(LW^{3,2}a^2 + b^3) \quad (57)$$

Por lo tanto, la salida de la capa 3, es la salida de interés de la Red Neuronal y puede ser descrita con la siguiente ecuación:

$$\mathbf{a}^3 = f^3(LW^{3,2}f^2(LW^{2,1}f^1(IW^{1,1}\mathbf{p} + \mathbf{b}^1) + \mathbf{b}^2) + \mathbf{b}^3) = \mathbf{y} \quad (58)$$

Una red multicapa es bastante poderosa. Por ejemplo, una red de dos capas, donde la primera capa es sigmoideal y la segunda capa es lineal, puede ser entrenada para ajustar cualquier función de una manera bastante adecuada (Demuth *et al.*, 2009).

Las Redes de retropropagación (Backpropagation) son una generalización de la regla de aprendizaje Widrow-Hoff (también conocida como mínimos cuadrados medios del error, LMS, least mean squares errors, por sus siglas en inglés) para redes multicapa y funciones de transferencia no lineales diferenciables. Se usan vectores de entrada y los correspondientes vectores objetivos para entrenar la red hasta que ésta pueda aproximar una función o asociar un vector específico de entrada a un vector específico de salida.

Widrow y Hoff tuvieron la idea de estimar el cuadrado medio del error $F(x)$ usando los cuadrados de los errores en cada iteración.

$$F(x) = (t(k) - a(k))^2 = e^2(k) \quad (59)$$

Después de cada iteración se calcula el gradiente:

$$\nabla F(x) = \nabla e^2(k) \quad (60)$$

Los primeros R elementos de $\nabla e^2(k)$ son derivados con respecto de los pesos de la red, mientras que los $R + 1$ elementos, son derivados con respecto de los sesgos (Hagan *et al.*, 1996). Entonces, se tiene:

$$[\nabla e^2(k)]_j = \frac{\partial e^2(k)}{\partial w_{1,j}} = 2e(k) \frac{\partial e(k)}{\partial w_{1,j}} \text{ para } j = 1, 2, \dots, R \quad (61)$$

$$[\nabla e^2(k)]_{R+1} = \frac{\partial e^2(k)}{\partial b} = 2e(k) \frac{\partial e(k)}{\partial b} \quad (62)$$

Ahora, la derivada parcial con respecto del error:

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial [t(k) - a(k)]}{\partial w_{1,j}} = \frac{\partial [t(k) - (Wp(k) + b)]}{\partial w_{1,j}} \quad (63)$$

O bien,

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} [t(k) - (\sum_{i=1}^R w_{1,i} p_i(k) + b)] \quad (64)$$

Donde $p_i(k)$ es el i^{th} elemento del vector de entradas a la k^{th} iteración. Esto se puede simplificar como:

$$\frac{\partial e(k)}{\partial w_{1,j}} = -p_j(k) \quad (65)$$

$$\frac{\partial e(k)}{\partial b} = -1 \quad (66)$$

Finalmente, cambiando la matriz de pesos y sesgos queda:

$$2\alpha e(k)p(k) \quad (67)$$

$$2\alpha e(k) \quad (68)$$

Estas dos ecuaciones forman la base del algoritmo de aprendizaje Widrow-Hoff (LMS). Los resultados se pueden extender al caso de capas múltiples, y escribirse en forma de matriz como:

$$W(k+1) = W(k) + 2\alpha e(k)p^T(k) \quad (69)$$

$$b(k+1) = b(k) + 2\alpha e(k) \quad (70)$$

Aquí, el error e , así como el sesgo b son vectores y α es la tasa de aprendizaje. Si α es grande, el aprendizaje ocurre rápidamente, pero si es demasiado grande, pueden surgir inestabilidades y los errores se pueden incrementar.

Una red estándar de retropropagación emplea el algoritmo del gradiente descendente, tal como la regla de aprendizaje Widrow-Hoff, en la cual, los pesos de la

red se mueven a través de la parte negativa del gradiente de la función de desempeño. El término, *retropropagación*, se refiere a la forma en que el gradiente es calculado para redes multicapa no lineales. Hay un gran número de variaciones, en el algoritmo básico, que están basadas en las técnicas de optimización estándar, tal como gradiente conjugado o el método de Newton.

La implementación más simple del algoritmo de aprendizaje, actualiza los pesos y sesgos de la red en la dirección en que la función de desempeño se hace pequeña más rápidamente. Una iteración de este algoritmo puede ser descrito de esta forma:

$$x_{k+1} = x_k - \alpha_k g_k \quad (71)$$

Donde, x_k es el vector con pesos y sesgos actuales, g_k es el gradiente actual y α_k es la tasa de aprendizaje.

Al igual que los métodos cuasi-Newton, el algoritmo de entrenamiento Levenberg-Marquardt, fue diseñado para alcanzar una velocidad de entrenamiento de segundo orden sin la necesidad de calcular la matriz Hessiana. Cuando la función de desempeño tiene la forma de una suma de cuadrados (como es típico en el entrenamiento de una red de retropropagación), entonces la matriz Hessiana puede ser aproximada como:

$$H = J^T J \quad (72)$$

Y el gradiente calculado por:

$$g = J^T e \quad (73)$$

Donde J es la matriz Jacobina que contiene las primeras derivadas de los errores de la red con respecto de los pesos y sesgos, e es el vector de errores de la red.

El algoritmo Levenberg-Marquardt usa la aproximación a la matriz Hessiana en la siguiente actualización tipo Newton.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (74)$$

Cuando en escalar μ es cero, entonces se tiene sólo el método Newton, usando la aproximación de la matriz Hessiana. Cuando μ es grande, se convierte en gradiente descendente. El método de Newton es más rápido y preciso, con un error mínimo, por lo tanto, el objetivo es llegar al método Newton tan pronto sea posible. Entonces μ se hace más pequeña después de cada iteración exitosa (reducción en la función de desempeño) y se incrementa solo cuando en un paso la función de desempeño se incrementa. De esta forma, la función de desempeño siempre se reduce en cada iteración del algoritmo (Demuth *et al.*, 2009).

Durante la investigación se evaluaron diferentes configuraciones de Redes Neuronales Artificiales para predecir la tasa de fotosíntesis en función de 5 variables climáticas medidas al interior del invernadero: 1) Radiación [Wm^{-2}], 2) Temperatura [$^{\circ}\text{C}$], 3) Humedad Relativa [%], 4) Déficit de Presión de Vapor [kPa] y, 5) Concentración de CO_2 [ppm]. La diferencia entre las configuraciones de la ANN probadas, radica en su estructura (número de capas que las integran y, número de neuronas en cada capa), así como el origen de los datos de entrenamiento, directos de los sensores o filtrados.

Se empleó el software Matlab (Neural Network Toolbox), para la creación, entrenamiento y validación de las redes. El tipo de red para los análisis fue en todos los casos de Retro-propagación (Feed-Forward Back-Propagation), con función de entrenamiento Levenberg-Marquardt; función de aprendizaje por Gradiente descendente

con momento; función de desempeño, Cuadrado Medio de Error ; función de transferencia, Hiperbólica Tangente Sigmoidal para las capas ocultas y función de transferencia lineal para la capa de salida. Lo anterior se debe a que, si en la capa de salida se emplean neuronas sigmoidales, la salida de la red se limita a un rango muy pequeño; por el contrario, al usar una neurona lineal, la salida puede tomar cualquier valor (Ljung, 2008).

3.8 Generación de las Rutas de la Fotosíntesis.

Para entender de manera general el comportamiento de la Fotosíntesis (de las plantas de tomate de los experimentos) como respuesta a diferentes condiciones de las variables que definen el microclima al interior del invernadero, se generaron superficies en 3 dimensiones de las funciones que describen las rutas que toma la fotosíntesis como consecuencia de esta interacción.

Para los registros del invernadero experimental de la Universidad Autónoma de Querétaro, cada función se creó empleando dos variables climáticas como entradas (con datos filtrados por medio del Método Savitzky Golay) y tomando en todos los casos como variable respuesta, la tasa de fotosíntesis que resulta de simular la mejor Red Neuronal Artificial.

Para la información recabada en los invernaderos experimentales de la Universidad Humboldt de Berlín, se combinaron los datos filtrados, tanto del Sistema Convencional como del Des-Fog, para crear la matriz que contiene las variables que determinan las condiciones climáticas de los invernaderos. El vector de valores para

fotosíntesis proviene de la unión de las salidas de las simulaciones de las mejores Redes Neuronales de ambos sistemas. La matriz de datos, resultante tiene más información de tendencias y patrones que si se les tratara de manera individual.

Las funciones se crearon para las siguientes combinaciones en contra de la Tasa de Fotosíntesis: 1) Temperatura-Concentración de CO_2 , 2) Radiación-Déficit de Presión de Vapor, 3) Humedad Relativa-Concentración de CO_2 , 4) Déficit de Presión de Vapor-Concentración de CO_2 , y 5) Temperatura-Humedad Relativa.

4. RESULTADOS Y DISCUSIÓN

4.1 INVERNADERO EXPERIMENTAL DEL CAMPUS AMAZCALA DE LA UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

En los siguientes apartados se muestran los resultados obtenidos al procesar las mediciones hechas en el Invernadero experimental del Campus Amazcala, de la Universidad Autónoma de Querétaro. Primero se explican, en la sección 4.1.1, las diferentes variables climáticas medidas, así como su relación con la Tasa de Fotosíntesis. Enseguida, en la sección 4.1.2, se aplica la *Teoría de Identificación de Sistemas* para encontrar un Modelo Matemático que prediga satisfactoriamente la tasa de Fotosíntesis Foliar, teniendo como base cinco variables climáticas de entrada. En la sección 4.1.3 se presenta la adaptación y calibración la *Sub-rutina del Modelo SUCROS* para simular la tasa de fotosíntesis efectuada por las plantas de tomate del experimento. Posteriormente, en la sección 4.1.4, se presenta la *Red Neuronal* que describe el Sistema Fotosíntesis al interior del Invernadero. Finalmente, se explica el efecto de la interrelación de dos variables climáticas en la tasa de Fotosíntesis, esto en la sección 4.1.5.

4.1.1 Comportamiento de las variables climáticas que afectan la fotosíntesis.

4.1.1.1 Fotosíntesis vs Radiación

El valor máximo registrado para la Radiación Fotosintéticamente Activa (PAR) durante los 55 días de muestreo fue de 225.1 Wm^{-2} . La Radiación es una de las principales fuentes de accionamiento de la fotosíntesis (Evans, 2000), puede verse en la Figura 4.1 cómo a medida que se da la elevación solar, las hojas de tomate comienzan con este proceso fisiológico.




Figura 4.1) Fotosíntesis vs Radiación PAR en los primeros cinco días de mediciones.

A pesar de la importancia de la radiación, puede verse que no es lineal la relación entre ella y la fotosíntesis, puesto que, como se ve en la Figura 4.1, mientras que en el día tres se registró cerca de la mitad de radiación que en el día uno, la tasa de fotosíntesis se mantienen casi constantes para esos días.

Las horas del día con radiación suman aproximadamente 12 a lo largo de los 55 días de mediciones tal como puede verse en la Figura 4.2. La razón de no tener curvas suaves (como funciones senoidales), se debe a la presencia de nubosidad, así como a las propias sombras generadas por la estructura y cubierta del invernadero estudiado.




Figura 4.2) Comportamiento de la Radiación PAR a lo largo de un día.

4.1.1.2 Fotosíntesis vs Temperatura

El invernadero experimental, cuenta con un sistema simple de apertura y cierre de ventanas que, además de controlar otras variables, se emplea principalmente para mantener la temperatura en los niveles *óptimos* para el desarrollo del cultivo de tomate, según lo reportado en la literatura para cada etapa fenológica (Lambers *et al.* 2008). Sin embargo, al ser un sistema sin un control preciso, las fluctuaciones de la temperatura son bastante grandes tal como se muestra en la Figura 4.3.

La máxima temperatura registrada es 34.11°C, mientras que la más baja es -2.63°C, lo que significa que durante los 55 días de estudio existe un rango de 36.74°C

en los que se mueve la temperatura del aire al interior del invernadero. Como se ve en la Figura 4.3, durante un día cualquiera, la fluctuación entre la temperatura más baja (normalmente cerca del amanecer) y la más alta del día puede oscilar en un rango de 20°C, por ejemplo el día dos de la misma figura (en la escala de tiempo corresponde al espacio entre 2 y 3).




Figura 4.3) Fotosíntesis vs Temperatura en los primeros cinco días de mediciones.

De igual forma que la radiación, la variable temperatura no es por sí misma capaz de explicar la ruta de la fotosíntesis, pues la diferencia entre las temperaturas de un día y otro son amplias, mientras que las tasas de fotosíntesis no varían en más de 1.0 $\mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$

4.1.1.3 Fotosíntesis vs Humedad Relativa

Similar al comportamiento de la variable temperatura, la Humedad Relativa del aire al interior del invernadero sufre grandes variaciones a lo largo de un día, puesto que,

debido a la necesidad de ventilar, al abrir las cortinas del invernadero, se da paso al aire proveniente del exterior que posee diferentes propiedades, tanto de temperatura como de humedad, afectando así el microclima que el propio cultivo genera.

En la Figura 4.4 puede verse una fluctuación de aproximadamente 60% en la humedad relativa del aire en un solo día. Para el conjunto de mediciones, el valor más bajo de esta variable es 21%, el más alto es 98.6%.




Figura 4.4) Fotosíntesis vs Humedad Relativa en los primeros cinco días de mediciones.

4.1.1.4 Fotosíntesis vs Concentración de CO_2

El dióxido de carbono (CO_2) presente en el aire es la principal fuente de suministro de carbono para la planta. Ésta, por medio del proceso de fotosíntesis, lo toma del ambiente para transformarlo después en materia seca, que puede ser dirigida al crecimiento de raíces, tallos, hojas, flores o frutos (Wilkinson, 2000).

Durante el proceso de fotosíntesis la concentración de CO_2 presente en el ambiente invernadero disminuye, debido al consumo de este gas por parte del propio cultivo, tal como se ve en la gráfica 4.5. Durante la noche la cantidad de este gas se incrementa, puesto que la planta en vez de ser consumidora, lo aporta al ambiente debido al proceso fisiológico conocido como respiración.




Figura 4.5) Fotosíntesis vs Concentración de CO_2 durante cuatro días de mediciones.

A medida que el cultivo se desarrolla, éste es capaz de incrementar la concentración de dióxido de carbono al interior del invernadero durante la noche (cuando las ventanas están cerradas). Esto es, una planta adulta genera más de este gas durante el proceso de respiración que una planta joven, tal como se muestra en la Figura 4.6, donde se observa que con 40 días más de desarrollo de las plantas, la concentración del CO_2 llega fácilmente a las 600 ppm. Sin embargo, cuando comienza el proceso de fotosíntesis, la asimilación de todo el dióxido de carbono almacenado durante la noche

se da de manera muy rápida, tal como lo muestra la pendiente de la curva en la misma figura para el día 40.

La concentración máxima del gas al interior del invernadero durante los 55 días de estudio llegó a 655.5 ppm, mientras que el más bajo fue de 313.6 ppm.




Figura 4.6) Trayectoria de la concentración de CO₂ al interior del invernadero como respuesta de los procesos de fotosíntesis y respiración.

4.1.1.5 Fotosíntesis vs Déficit de Presión de Vapor

Durante el proceso de transpiración, las hojas de las plantas ingresan a su interior moléculas de CO₂, mientras que liberan al exterior de sus cutículas, moléculas de agua a través de pequeñas estructuras llamadas estomas. La apertura y cierre de los estomas y, por lo tanto, la cantidad de dióxido de carbono que puede ingresar por unidad de tiempo, para ser usado en el proceso de fotosíntesis, está directamente relacionado con el Déficit de Presión de Vapor (VPD, por sus siglas en inglés). Se han acumulado muchas evidencias, tanto en campo abierto como en ambientes controlados, de que muchas

plantas cierran sus estomas a medida que el DPV se incrementa, presumiblemente como mecanismo para conservar agua (Monteith, 1990).

En la Figura 4.7 se muestra la relación entre el déficit de presión de vapor y las tasas de fotosíntesis. El máximo VPD registrado hasta el 27 de diciembre es de 3.39 kPa. El mínimo es muy cercano a cero, cuando la atmósfera dentro del invernadero está a saturación de vapor de agua.




Figura 4.7) Fotosíntesis vs Déficit de Presión de Vapor durante 4 días de mediciones.

Al analizar por separado cada una de las cinco variables climáticas arriba expuestas es claro que no es posible encontrar una relación directa entre cada una de ellas y la tasa de fotosíntesis medida. Esto se debe a que el comportamiento de este proceso fisiológico es no lineal y depende de todas las variables para ser descrito con precisión, tal como se muestra en la Figura 4.8.




Figura 4.8) Variables climáticas que afectan el proceso de Fotosíntesis. De arriba hacia abajo, Tasa de Fotosíntesis, Temperatura, Humedad Relativa, Déficit de Presión de Vapor, Concentración de CO₂ y, Radiación PAR.

4.1.2 Metodología de la Identificación de Sistemas aplicada a Fotosíntesis.

Como parte de un primer intento por encontrar un modelo que permita predecir el comportamiento de la Fotosíntesis al interior del invernadero, se indagó en diferentes Modelos Matemáticos Dinámicos derivados de la Teoría de Identificación de Sistemas.

El Modelo Dinámico Lineal de Autoregresión con Variables Exógenas (ARX), mostró el mejor comportamiento, teniendo en cuenta el grado de ajuste de las simulaciones y predicciones contra mediciones. Modelos como los Auto-regresivos con Promedio Móvil y Entradas Exógenas (ARMAX), Box-Jenkins (BJ), Error de la salida (OE), incluso, los modelos ARX NO LINEALES, mostraron un comportamiento pobre (ajuste por debajo de 30% entre los datos de validación y la simulación de los modelos) en la predicción de la tasa de fotosíntesis foliar de las plantas de tomate al interior del

invernadero, dadas cinco variables de entrada: 1) Radiación, 2) Temperatura, 3) Humedad Relativa, 4) Déficit de Presión de Vapor y, 5) Concentración de CO₂.

En los Cuadros 1 y 2 se presenta el resumen de los resultados obtenidos después de realizar más de 10^{11} combinaciones en la estructura del modelo ARX, para cada uno de los dos sub-conjuntos de datos, 80% estimación, 20% validación y 60% estimación, 40% validación, respectivamente.

Cuadro 1. Mejores Modelos ARX obtenidos, usando 80% de los datos para estimación y 20% para validación del modelo.

Estructura											Función de		
na	nb					nk					FPE (x 10-3)	pérdida (x 10-3)	AJUSTE (%)
6	2	2	2	5	4	2	1	2	4	6	4.639	4.589	51.25
6	2	2	2	5	5	2	1	2	4	5	4.634	4.582	51.19
6	2	1	2	1	5	2	1	1	1	5	4.745	4.704	50.62
3	2	2	2	4	3	2	1	2	5	7	4.805	4.766	50.31
7	2	4	4	5	5	2	1	2	4	5	4.615	4.551	50.30
6	2	1	2	1	6	2	1	1	1	4	4.736	4.692	49.83
6	2	2	2	4	3	2	1	2	5	7	4.643	4.598	49.60
10	2	2	2	2	7	2	3	2	3	3	4.734	4.673	49.15
3	2	1	2	1	3	2	1	1	1	6	4.913	4.883	48.60
6	2	2	2	2	4	2	3	2	3	3	4.824	4.779	47.42

na : número de retrasos de la variable temperatura dentro del invernadero.

nb : número de retrasos para las variables de entrada temperatura externa, radiación solar, humedad relativa y velocidad del viento.

nk : retardo entre las variables de entrada y salida.

FPE: error de predicción final de Akaike.

De los dos conjuntos de datos el Modelo ARX que mejor comportamiento tiene se encuentra en el cuadro que emplea el 80% de datos para estimación y 20% de datos para validación. El orden del modelo es: na=[7], nb=[2 4 4 5 5], nk= [2 1 2 4 5], con un grado de ajuste en la simulación de los datos de validación de 50.3%; la razón de su elección es el error de predicción final de Akaike = 4.615, que es el menor para los dos conjuntos de datos. Así mismo, la varianza del modelo elegido es 4.551×10^{-3} , 10 veces

menor al de la varianza del mejor modelo con datos 60%-40%, que asciende a 5.067×10^{-3} .

Cuadro 2. Mejores Modelos ARX obtenidos, usando 60% de los datos para estimación y 40% para validación del modelo.

											Función de		
Estructura											FPE	pérdida	AJUSTE
na	nb					nk					(x 10-3)	(x 10-3)	(%)
7	5	2	5	5	3	2	1	2	5	4	5.218	5.123	54.14
7	5	2	3	5	3	2	1	2	5	4	5.214	5.126	53.77
7	2	2	5	5	3	2	1	2	5	4	5.219	5.134	53.45
7	2	2	2	5	3	2	1	2	5	4	5.216	5.141	53.39
7	2	2	3	5	3	2	1	2	5	4	5.215	5.137	53.11
7	2	2	2	4	3	2	1	2	5	4	5.221	5.150	52.44
6	2	2	2	4	3	2	1	2	5	4	5.228	5.161	50.53
10	9	1	1	9	1	1	1	1	1	1	5.248	5.138	49.55
9	5	2	5	5	3	2	10	10	5	4	5.169	5.067	48.45
10	2	1	1	10	3	2	1	2	5	4	5.182	5.087	46.49

na : número de retrasos de la variable temperatura dentro del invernadero.

nb : número de retrasos para las variables de entrada temperatura externa, radiación solar, humedad relativa y velocidad del viento.

nk : retardo entre las variables de entrada y salida.

FPE: error de predicción final de Akaike.

La *simulación* del modelo ARX seleccionado (se toman los datos de validación) se presenta en la Figura 4.9; es notoria la baja capacidad de este modelo lineal en el correcto seguimiento de la tendencia de la variable respuesta fotosíntesis.

Sin embargo, empleando el mismo modelo en *predicción 5 pasos hacia adelante*, el grado de ajuste crece considerablemente, hasta 89.61% (Figura 4.10) para el mismo conjunto de datos de validación. La razón radica en que, durante la predicción, la variable salida es tomada en cuenta para recalcular la nueva; esto es, la predicción de las salidas futuras de un modelo a partir de datos previos sobre un horizonte temporal de k muestras o $k(T_s)$ unidades de tiempo requiere, tanto las entradas como las salidas en el pasado. La predicción se usa en control, donde se desea pronosticar la salida para un

número específico de pasos dado. Los valores de $y(t)$ predichos k pasos adelante, se calculan usando las entradas $u(s)$ y las salidas $y(s)$, $s \leq (t-k)$, donde s : número de muestra de datos (Ljung, 2007).




Figura 4.9) Simulación del mejor Modelo ARX. El grado de ajuste es del 50.3%




Figura 4.10) Predicción del Modelo ARX. El grado de ajuste se incrementa a 89.61%.

Se empleó el Método de Validación Cruzada para verificar cuál es el comportamiento del modelo con respecto de la prueba de Residuales. La función de Autocorrelación de los Residuales (Figura 4.11) del Modelo $na=[7]$, $nb=[2\ 4\ 4\ 5\ 5]$, $nk=[2\ 1\ 2\ 4\ 5]$, está dentro de los intervalos de confianza del 99% en 14 de 25 puntos; un comportamiento similar lo presenta la correlación cruzada de la Radiación y el Déficit de Presión de Vapor con los residuales de la Fotosíntesis, pues a pesar de que no están totalmente dentro de los mismos límites de confianza, lo están en más del 50% (Figura 4.12) y 70% (Figura 4.15) respectivamente. Las funciones de correlación cruzada entre la Temperatura (Figura 4.13), Humedad Relativa (Figura 4.14) y Concentración de CO_2 (Figura 4.16) contra los residuales de la salida Fotosíntesis, se encuentran dentro de los intervalos de confianza indicados anteriormente.




Figura 4.11) Función de Autocorrelación de los residuales para el Modelo ARX.




Figura 4.12) Función de Correlación cruzada entre la variable de entrada Radiación y residuales de la variable de salida Fotosíntesis.




Figura 4.13) Función de Correlación cruzada entre la variable de entrada Temperatura y residuales de la variable de salida Fotosíntesis.




Figura 4.14) Función de Correlación cruzada entre la variable de entrada Humedad Relativa y la variable de salida Fotosíntesis.




Figura 4.15) Función de Correlación cruzada entre la variable de entrada Déficit de Presión de Vapor y la variable de salida Fotosíntesis.




Figura 4.16) Función de Correlación cruzada entre la variable de entrada CO₂ y la variable de salida Fotosíntesis.

La estructura completa del Modelo $na=[7]$, $nb=[2\ 4\ 4\ 5\ 5]$, $nk=[2\ 1\ 2\ 4\ 5]$, se presenta en la siguiente ecuación:

$$Ti(t) = \frac{[Rad(t)Temp(t)HR(t)VPD(t)CO_2(t)]}{1 - 2.46q^{-1} + 1.935q^{-2} - 0.2208q^{-3} - 0.5446q^{-4} + 0.353q^{-5} - 0 - 0.01467q^{-6} - 0.04605q^{-7}}$$

$$\begin{pmatrix} 0.002557q^{-2} & -0.002562q^{-3} & & & & & \\ 0.02781q^{-1} & -0.0309q^{-2} & -0.01578q^{-3} & 0.01873q^{-4} & & & \\ & -0.01127q^{-2} & +0.02302q^{-3} & -0.01306q^{-4} & +0.001182q^{-5} & & \\ -0.06587q^{-4} & +0.9727q^{-5} & -2.375q^{-6} & +2.098q^{-7} & -0.6333q^{-8} & & \\ & 0.002416q^{-5} & -0.004891q^{-6} & +0.005415q^{-7} & -0.006236q^{-8} & +0.003345q^{-9} & \end{pmatrix}$$

Donde:

Rad (t) = Variable de entrada Radiación PAR

Temp (t) = Variable de entrada Temperatura

RH (t) = Variable de entrada Humedad Relativa

VPD (t) = Variable de entrada Déficit de presión de Vapor

CO₂ (t) = Variable de entrada concentración de CO₂

Finalmente, de acuerdo con los valores de los coeficientes, la variable de entrada más importante para la Fotosíntesis es la Temperatura, seguida por la Humedad Relativa, Radiación Fotosintéticamente Activa, Déficit de Presión de Vapor y Concentración de CO₂.

4.1.3 Modelo Mecanicista de Goudriaan para predicción de la Fotosíntesis Foliar.

Después de haber filtrado los datos con el Método Savitzky Golay, es muy importante considerar la variación del horario de verano en los datos. Para México, el horario de verano (con una hora adelantada) culmina el último domingo del mes de octubre. Debido a que la computadora en la que se descargaba la memoria del Sensor de Fotosíntesis, PTM-48 y del sensor de Radiación no fue modificada en el cambio de horario, para los datos que van del 3 de noviembre de 2009 al 27 de diciembre del mismo año, se tuvieron que eliminar los datos de una hora de mediciones. Según lo establece el Centro Nacional de Metrología (CENAM), esta modificación se realizó con los datos del primer día de registros, esto es, a las 2 am.

De los parámetros que considera el Modelo Mecanicista de Goudriaan, contenido en la subrutina del Modelo SUCROS (Simple and Universal Crop Simulator), para calcular la fotosíntesis foliar (este modelo la reporta en unidades de $\text{mgCO}_2\text{m}^{-2}\text{s}^{-1}$, por lo tanto, durante la evaluación de esta sección se trabajara en dichas unidades) , tanto Latitud como A_{max} (Tasa máxima de fotosíntesis), se consideran constantes en 20.70 ($20^{\circ}42'$ Latitud Norte: ubicación del Invernadero en el Campus Amazcala de la Universidad Autónoma de Querétaro) y $0.8815 [\text{mgCO}_2\text{m}^{-2}\text{s}^{-1}]$ respectivamente (ver Figura 4.17). El parámetro Índice de Área Foliar (LAI, por sus siglas en inglés, tal como aparece en el modelo) se toma como la unidad, puesto que se debe comparar la fotosíntesis registrada por el Fitomonitor PTM-48, reportada por metro cuadrado de hoja, $[\text{mgCO}_2\text{m}_h^{-2}\text{s}^{-1}]$, contra las predicciones de la sub-rutina del Modelo SUCROS, con unidades por metro se superficie $[\text{mgCO}_2\text{m}_s^{-2}\text{s}^{-1}]$.




Figura 4.17) La tasa máxima de fotosíntesis (A_{max}) es un parámetro medido a lo largo de los días de estudio.

La deducción para tomar $LAI=1$ es la siguiente:

$$LAI = 1 = \frac{1m_h^2}{1m_s^2}$$

Donde:

m_h^2 = metro cuadrado de hoja

m_s^2 = metro cuadrado de superficie

La tasa de fotosíntesis que registra el Modelo SUCROS se da por metro cuadrado de superficie, por lo tanto, para hacer compatibles las unidades y poder comparar entre una y otra tasa, se hace el siguiente producto:

$$Fotosíntesis (SUCROS) * (1)$$

$$1 = \left[\frac{1}{\frac{1m_h^2}{1m_s^2}} \right]$$

$$\left[\frac{mgCO_2}{m_s^2 * s} \right] * \left[\frac{1}{\frac{1m_h^2}{1m_s^2}} \right] = \left[\frac{mgCO_2}{m_h^2 * s} \right]$$

Por lo tanto, al tomar LAI=1, se puede decir que las unidades de las tasas de fotosíntesis entre las predicciones del modelo SUCROS y las mediciones, son las mismas, dadas en metro cuadrado de hoja.

Los parámetros: Coeficiente de Dispersión de las Hojas para PAR, **SCP** (adimensional); Coeficiente de Extinción de la Radiación, **KDF** (adimensional); Eficiencia del Uso de la Radiación, **EFF** [mgCO₂J⁻¹]; así como el Coeficiente de Transmisitividad Atmosférica, **ATMTR** (adimensional), se calibraron para un día y 5 días de mediciones, tanto para Fotosíntesis únicamente, como para la relación Fotosíntesis-Radiación PAR. Para esta última relación, la calibración de la Radiación se realizó entre la PAR registrada, y la salida y(6) (Radiación Fotosintéticamente Activa Teórica disponible al interior del invernadero) del modelo en Matlab Simulink. En el Cuadro 3 se presentan los valores propuestos como semilla para cada calibración. En los Cuadros 4 al .7 se presentan los valores obtenidos para cada parámetro.

Cuadro 3. Valores semilla propuestos para cada una de las 10 calibraciones.

Parámetro	1	2	3	4	5	6	7	8	9	10	Incremento
SCP	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.999	0.100
KDF	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.999	0.100
EFF	0.001	0.006	0.012	0.017	0.023	0.028	0.034	0.039	0.045	0.050	0.005
ATMTR	0.125	0.181	0.236	0.292	0.347	0.403	0.458	0.514	0.569	0.625	0.056

Los límites para cada parámetro se proponen de acuerdo a Goudriaan & Van Laar (1994). El límite superior para ATMTR considera la pérdida de transmisitividad a causa de la cubierta del Invernadero.

Cuadro 4. Calibraciones del día Juliano 311 (07 de Noviembre de 2009) para la Variable de salida Fotosíntesis.

PARÁMETROS CALIBRADOS - [FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.1634	0.1000	0.1021	0.1184	0.1442	0.2253	0.9548	0.9527	0.9539	0.9616
KDF	0.3553	0.3869	0.3451	0.3420	0.3530	0.3585	0.7938	0.7971	0.8026	0.7009
EFF	0.0478	0.0442	0.0482	0.0488	0.0479	0.0485	0.0408	0.0392	0.0398	0.050
ATMTR	0.2241	0.2219	0.2234	0.2232	0.2234	0.2236	0.4255	0.4326	0.4289	0.3995
R2*	0.9687	0.9686	0.9687	0.9687	0.9687	0.9687	0.9714	0.9714	0.9714	0.9714
CME*	0.0033	0.0033	0.0033	0.0033	0.0033	0.0033	0.003	0.003	0.003	0.003
RCME*	0.0574	0.0574	0.0574	0.0574	0.0574	0.0574	0.0546	0.0546	0.0546	0.0546
R2+	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844
CME+	730.99	761.07	739.83	742.73	740.07	737.59	812.97	918.16	863.04	488.28
RCME+	27.037	27.588	27.200	27.253	27.204	27.159	28.513	30.301	29.378	22.097

(*) Fotosíntesis (+) PAR

Cuadro 5. Calibraciones del día Juliano 311 (07 de Noviembre de 2009) para las Variables de salida Fotosíntesis y PAR.

PARÁMETROS CALIBRADOS - [PAR & FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.5167	0.3473	0.2826	0.3842	0.7259	0.8593	0.8664	0.9310	0.9467	0.9638
KDF	0.6784	0.7027	0.5746	0.5830	0.6549	0.7381	0.7263	0.8272	0.8649	0.999
EFF	0.0237	0.0212	0.0237	0.0245	0.0285	0.0337	0.0347	0.0420	0.0456	0.050
ATMTR	0.3218	0.3218	0.3218	0.3218	0.3218	0.3218	0.3218	0.3218	0.3218	0.3218
R2*	0.9676	0.9675	0.9673	0.9674	0.9682	0.9686	0.9687	0.9691	0.9694	0.9696
CME*	0.0034	0.0034	0.0035	0.0035	0.0034	0.0033	0.0033	0.0033	0.0032	0.0032
RCME*	0.0586	0.0587	0.0588	0.0587	0.0583	0.0577	0.0577	0.057	0.0568	0.0565
R2+	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844	0.9844
CME+	71.494	71.494	71.494	71.494	71.494	71.494	71.494	71.494	71.494	71.494
RCME+	8.4554	8.4554	8.4554	8.4554	8.4554	8.4554	8.4554	8.4554	8.4554	8.4554

(*) Fotosíntesis (+) PAR

Cuadro 6. Calibraciones de los días Julianos 339 al 343 (05 -09 de diciembre de 2009) para la Variable de salida Fotosíntesis.

PARÁMETROS CALIBRADOS - [FOTOSINTESIS]										
5 DIAS	1	2	3	4	5	6	7	8	9	10
SCP	0.2156	0.1312	0.1439	0.1765	0.2533	0.3211	0.3163	0.9858	0.9858	0.9238
KDF	0.2636	0.2593	0.2707	0.2676	0.2666	0.2801	0.2550	0.9990	0.9990	0.999
EFF	0.0418	0.0414	0.0400	0.0408	0.0421	0.0414	0.0447	0.0500	0.0500	0.013
ATMTR	0.2218	0.2214	0.2216	0.2218	0.2209	0.2214	0.2219	0.3181	0.3181	0.625
R2*	0.9474	0.9474	0.9474	0.9474	0.9474	0.9474	0.9474	0.9484	0.9484	0.9495
CME*	0.0033	0.0033	0.0033	0.0033	0.0033	0.0033	0.0033	0.0033	0.0033	0.0032
RCME*	0.0577	0.0577	0.0577	0.0577	0.0577	0.0577	0.0577	0.0572	0.0572	0.0567
R2+	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505
CME+	1089.3	1094.8	1092.2	1089.4	1102.6	1096.1	1088.2	264.9	264.9	4975.3
RCME+	33.005	33.088	33.048	33.006	33.206	33.108	32.987	16.276	16.276	70.536

(*) Fotosíntesis (+) PAR

Cuadro 7. Calibraciones de los días Julianos 339 al 343 (05 -09 de diciembre de 2009) para las Variables de salida Fotosíntesis y PAR.

5 DIAS	PARÁMETROS CALIBRADOS - [PAR & FOTOSÍNTESIS]									
	1	2	3	4	5	6	7	8	9	10
SCP	0.8276	0.5157	0.3234	0.6050	0.6421	0.9265	0.9028	0.9484	0.9587	0.98
KDF	0.5971	0.5099	0.4398	0.5273	0.4831	0.6557	0.5997	0.7144	0.7593	0.999
EFF	0.022	0.0178	0.0183	0.0185	0.0203	0.0289	0.0275	0.0317	0.0337	0.040
ATMTR	0.3433	0.3433	0.3433	0.3433	0.3433	0.3433	0.3433	0.3433	0.3433	0.3433
R2*	0.9468	0.9456	0.9452	0.9458	0.9458	0.9475	0.9473	0.9479	0.948	0.9484
CME*	0.0034	0.0034	0.0035	0.0034	0.0034	0.0033	0.0033	0.0033	0.0033	0.0033
RCME*	0.0582	0.0587	0.0589	0.0586	0.0586	0.0577	0.0578	0.0575	0.0574	0.0573
R2+	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505	0.9505
CME+	230.74	230.74	230.74	230.74	230.74	230.74	230.74	230.74	230.74	230.74
RCME+	15.190	15.190	15.190	15.190	15.190	15.190	15.190	15.190	15.190	15.190

(*) Fotosíntesis (+) PAR

Para el cuadro de calibraciones de **1 día para fotosíntesis**, a partir de la 7ª calibración, los resultados ya no son permicibles, puesto que el valor de SCP es mayor al de KDF y, de acuerdo a otras calibraciones hechas para el mismo modelo (Goudriaan & Van Laar, 1994), esto no es aceptable. De este cuadro, se elige la primer calibración, a pesar de que el ajuste en fotosíntesis es es igual al del resto de calibraciones válidas, sin embargo, la raíz del cuadrado medio de los errores para PAR es la menor de todo el cuadro, 27.037.

Bajo el mismo principio explicado arriba se eligen las mejores calibraciones, tanto para **1 día Fotosíntesis y PAR**, como para **5 días** en sus dos modalidades, ver Cuadro 8. De este cuadro puede notarse que la predicción a 1 día, de la subrutina del modelo SUCROS para la variable Fotosíntesis, es prácticamente la misma cuando se calibra con una o dos variables a la vez (columna 1 y 2, respectivamente); sin embargo, es preferible emplear los parámetros calibrados para PAR y Fotosíntesis al mismo tiempo, pues la raíz del cuadrado medio del error (RCME) es mas de 300% menor (8.4554) que si se calibra solo para ajustar fotosíntesis (27.037).

Cuadro 8. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis para Querétaro.

Parámetro	1 DIA	1 DIA	5 DIAS	5 DIAS
	Fotosíntesis	Foto & PAR	Fotosíntesis	Foto & PAR
SCP	0.1634	0.5167	0.2156	0.3234
KDF	0.3553	0.6784	0.2636	0.4398
EFF	0.0478	0.0237	0.0418	0.0183
ATMTR	0.2241	0.3218	0.2218	0.3433
R2*	0.9687	0.9676	0.9474	0.9452
CME*	0.0033	0.0034	0.0033	0.0035
RCME*	0.0574	0.0586	0.0577	0.0589
R2+	0.9844	0.9844	0.9505	0.9505
CME+	730.99	71.494	1089.3	230.74
RCME+	27.037	8.4554	33.005	15.19

(*) Fotosíntesis

(+) PAR

Por otra parte, la diferencia entre el ajuste de fotosíntesis con la calibración de un día y la de 5 días es de aproximadamente 2%, siendo superior el ajuste en la primera. A pesar de esto, la RCME se mantiene prácticamente en el mismo valor para ambos tipos de calibraciones; sin embargo, la diferencia entre la RCME para PAR, entre la calibración para 5 días (columna 4) y la de un día (para PAR y Fotosíntesis al mismo tiempo, columna 2) es dos veces mayor en la primera. De igual manera, el ajuste para PAR es 3% menor en 5 días comparado con el ajuste con la calibración de 1 día.

A pesar de lo anterior, se eligen los parámetros de la cuarta columna [**SCP KDF EFF ATMTR**]=[**0.3234 0.4398 0.0183 0.3433**] del cuadro anterior, pues representan de mejor manera a todo el conjunto de datos. Si se eligieran los parámetros de la calibración de un día, el modelo estaría sobreestimado. En las Figuras 4.18 a 4.22 se observa el comportamiento de la sub-rutina del modelo SUCROS para predecir Fotosíntesis y Radiación PAR disponible al introducir estos parámetros.




Figura 4.18) Fotosíntesis Teórica vs Medida para los días Julianos 339-343.




Figura 4.19) Regresión Fotosíntesis para los días Julianos 339 - 343.




Figura 4.20) Radiación PAR medida por el sensor dentro del invernadero vs PAR teórica. Días Julianos 339 – 343.




Figura 4.21) Regresión Radiación Fotosintéticamente Activa Disponible para los días Julianos 339-343.




Figura 4.22) Radiación Teórica Absorbida por el Dosel vs Radiación PAR Medida dentro del Invernadero. Días Julianos 339- 343.

Finalmente en la Figura 4.23 se presenta la simulación del Modelo Sucros para la declinación de la tasa de fotosíntesis en función del día del año y la hora del día, para los 55 días de Mediciones realizadas en Querétaro. Cada curva representa un día, al graficar todas en un sola Figura parece que forman una superficie.




Figura 4.23) La declinación de la Fotosíntesis está en función de la elevación solar a través del tiempo. Se grafica para los días 307 al 361.

En la gráfica 4.24 se presenta la simulación del día Juliano 311 (7 de noviembre) con el modelo ya calibrado. La finalidad es ver a mayor detalle el comportamiento de la Sub-rutina de SUCROS en la predicción de la Tasa de Fotosíntesis Foliar.




Figura 4.24) Fotosíntesis Teórica del modelo SUCROS vs Fotosíntesis medida para el día Juliano 311.

Como puede verse en la Figura anterior, el grado de ajuste del modelo ya calibrado es aceptable, más no ideal. Esto se debe a que el Modelo Mecanicista de Goudriaan contenido en la Subrutina del Modelo SUCROS que calcula la tasa de fotosíntesis foliar, lo hace en *función de la elevación solar* para un día Juliano dado. El modelo solo toma la cantidad de radiación PAR disponible, así como parámetros que solo definen su impacto sobre el dosel (SCP, KDF, EFF, ATMTR) como única variable que influye en

el comportamiento de la fotosíntesis foliar, dejando a un lado el resto de variables climáticas tales como temperatura, humedad relativa y concentración de CO_2 .

A pesar de estar contenido el parámetro de la transmisibilidad atmosférica (ATMTR) en la subrutina del modelo SUCROS, éste no es capaz de describir en su totalidad el curso de la radiación PAR a lo largo del día, pues, como se ve en la Figura 4.25, el efecto del paso esporádico de nubes sobre el área de estudio no está contemplado. Además, el modelo fue desarrollado para cultivos a campo abierto, en donde no hay problemas que se generan en cultivos bajo invernadero: sombras generadas por la propia estructura y por la cubierta.




Figura 4.25) PAR Teórica vs PAR medida para el día Juliano 311.

4.1.4 Redes Neuronales aplicadas al Sistema Fotosíntesis

Se evaluaron diferentes configuraciones de Redes Neuronales Artificiales (ANN por sus siglas en inglés, Artificial Neural Networks) para predecir la tasa de fotosíntesis en función de 5 variables climáticas medidas al interior del invernadero: 1) Radiación, 2) Temperatura, 3) Humedad Relativa, 4) Déficit de Presión de Vapor y, 5) Concentración de CO₂. La diferencia entre las configuraciones de la ANN probadas, radica en su estructura (número de capas que las integran y, número de neuronas en cada capa), así como el origen de los datos de entrenamiento, ya sea directos de los sensores o filtrados.

El tipo de red para los análisis fue en todos los casos de Retro-propagación (Feed-Forward Back-Propagation), con función de entrenamiento Levenberg-Marquardt (TRAINLM); función de aprendizaje por Gradiente descendente con momento (LEARNGDM); función de desempeño, Cuadrado Medio de Error (MSE, por sus siglas en inglés, Mean Squared Error); función de transferencia, Hiperbólica Tangente Sigmoidal (TANSIG) para las capas ocultas y función de transferencia lineal (PURELIN) para la capa de salida. Lo anterior se debe a que, si en la capa de salida se emplean neuronas Sigmoidales, la salida de la red se limita a un rango muy pequeño; por el contrario, al usar una neurona lineal, la salida puede tomar cualquier valor.

Después de varios procesos de iteración, se toman como Redes válidas, aquellas en las que el grado de ajuste del modelo tanto en validación como en prueba, es menor que en estimación, en caso contrario, se obtendría una Red Neuronal que sobreestima los datos. Las mejores redes se presentan a continuación (ver Cuadros 9 y 10).

Cuadro 9. Estadísticos de las mejores configuraciones de red para los datos no filtrados.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	96.08	96.37	96.75	R^2
	2.8634	2.6591	2.3283	CME
3	5,5	10,5	15,5	*
	96.412	97.147	97.103	R^2
	2.522	2.0925	2.4382	CME
	5,10	10,10	15,10	*
	96.363	97.052	97.182	R^2
	2.7722	2.3559	2.1714	CME
	5,15	10,15	15,15	*
	97.034	96.867	97.248	R^2
	2.2567	2.1152	1.9802	CME
4	10,10,10	10,15,10	15,10,15	*
	96.876	97.08	97.491	R^2
	2.6573	2.4661	2.4434	CME
	15,10,10	15,15,10	15,15,15	*
	97.349	97.188	97.576	R^2
	2.1972	2.4374	2.6369	CME

(*) Número de neuronas en las capas ocultas.

Cuadro 10. Estadísticos de las mejores configuraciones de red para los datos filtrados por medio del método Savitzky Golay.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	97.35	97.672	97.816	R^2
	1.8387	1.5937	1.5065	CME
3	5,5	10,5	15,5	*
	97.638	97.813	98.147	R^2
	1.6749	1.7101	1.4984	CME
	5,10	10,10	15,10	*
	98.016	98.241	98.369	R^2
	1.6603	1.3203	1.2688	CME
	5,15	10,15	15,15	*
	98.019	98.276	98.697	R^2
	1.4319	1.3082	1.1821	CME
4	10,10,10	10,15,10	15,10,15	*
	98.522	98.821	98.879	R^2
	0.99778	0.99088	1.0115	CME
	15,10,10	15,15,10	15,15,15	*
	98.692	98.584	98.89	R^2
	1.1807	1.2792	1.1678	CME

(*) Número de neuronas en las capas ocultas.

Para los datos sin filtrar el mejor desempeño lo tiene la Red Neuronal con la siguiente configuración: 3 capas y 15 neuronas en ambas capas ocultas. Como puede verse, se logró un ajuste del 97.248% con un cuadrado medio del error igual a 1.9802.

En el caso de los datos filtrados con el método Savitzky Golay, el mejor desempeño lo tiene la Red Neuronal con la siguiente configuración: 4 capas, 10 neuronas en la primera capa oculta, 15 en la segunda y 10 más en la tercera. El ajuste llega a 98.821% con un cuadrado medio del error de 0.9908.

Al comparar las mejores Redes Neuronales generadas (ver Cuadro 11), tanto para datos de entrada sin filtrar (Red -1) como para los datos filtrados por Savitzky Golay (Red-2), tenemos que: a pesar de que la Red-1 es más simple en estructura, su grado de ajuste es sólo 1.573% menor que la red generada con datos filtrados; sin embargo, al tomar en cuenta el cuadrado medio del error, resulta que la Red-2 tiene únicamente el 50.03% del error generado por la red de datos directos de los sensores. Por lo tanto, la Red Neuronal más eficiente es la generada con datos filtrados, a pesar de ser más compleja en arquitectura.

Cuadro 11. Comparación entre las mejores redes neuronales para cada tipo de datos de entrada.

Origen de los datos	Estructura de la red		Estadísticos	
	Número de capas	Neuronas en capas ocultas	R ²	CME
Sin filtrar	3	15-15	97.248	1.9802
Filtrados	4	10-15-10	98.821	0.9908

4.1.4.1 Simulación de la mejor Red Neuronal

Una vez elegida la mejor Red Neuronal se emplea para realizar la Simulación de todos los datos, tanto de las variables climáticas al interior del invernadero, como del

Fitomonitor, y se recalcula el grado de ajuste, así como el Cuadrado Medio del Error. Esto se hace porque el R^2 y CME reportados por el Neural Network Toolbox Graphical User Interface de MATLAB (ver Figura 4.26), es el promedio de esos estadísticos para tres subconjuntos que provienen del 100% de datos: Entrenamiento (50%), Validación (25%) y Prueba (25%). Los datos de cada subconjunto se eligen de forma aleatoria a lo largo de la matriz de información.




Figura 4.26) Ajuste de la mejor Red Neuronal para los subconjuntos: entrenamiento, validación y prueba. En el cuarto cuadrante (derecha, inferior) se encuentra el promedio de estos.

En la Figura 4.27 se muestra la Simulación de la Red Neuronal para todos los datos tomados durante el periodo de experimentación; se observa el comportamiento que tiene la fotosíntesis cuando tiene las siguientes variables de entrada: 1) Radiación PAR (Wm^{-2}), 2) Temperatura ($^{\circ}\text{C}$), 3) Humedad Relativa (%), 4) Déficit de Presión de Vapor (kPa) y 5) disponibilidad de CO_2 al interior del invernadero (ppm).




Figura 4.27) Comportamiento de la Fotosíntesis al simular la mejor Red neuronal, cuando se ingresa la matriz de variables de entrada de tamaño 4820 x 5.

Haciendo un acercamiento (Figura 4.28) se aprecia lo bien que trabaja la red, con lo que queda clara la alta capacidad de las redes neuronales artificiales para ajustar modelos altamente no lineales, en este caso la fotosíntesis.




Figura 4.28) Simulación de la ANN para los datos de seis días.

Para evaluar el comportamiento general de la Red Neuronal elegida (a lo largo de los 4820 puntos de mediciones), se emplea el Curve Fitting Tool de MatLab. Los estadísticos de la regresión lineal aplicada (Figura 4.29) entre datos medidos y simulados son los siguientes:

Modelo polinomial de primer orden:

$$f(x) = p1 * x + p2$$

Coeficientes del modelo con los intervalos de confianza al 95%:

$$p1 = 0.9814(0.977,0.9858)$$

$$p2 = 0.1085(0.07555,0.1415)$$

Suma de los cuadrados del error (SCE)= 4111

Ajuste de la regresión: $R^2 = 0.9756$

Cuadrado medio del error: CME= 0.8532

Raíz del CME: RCME= 0.9237




Figura 4.29) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones.

Con la regresión lineal se logra 97.56% de ajuste entre los valores de Fotosíntesis simulada con la Red Neuronal y la Fotosíntesis medida. Así mismo, se puede observar claramente como la mayor parte de la nube de puntos cae dentro de los límites de confianza al 95% para la ecuación de ajuste, lo cual se debe a que la raíz del Cuadrado Medio del Error (RCME) es bajo, 0.9237.

Al realizar las pruebas estadísticas a la Red Neuronal de 4 capas y 10-15-10 neuronas en las capas ocultas, para los datos de entrada filtrados por el Método Savitzky Golay, se observa el excelente desempeño de ésta para todo el conjunto de datos. El valor del ajuste en la regresión mostrada en la Figura 4.29, es sólo 1.261% menor al reportado por el Neural Network Toolbox Graphical User Interface de MATLAB. El Cuadrado Medio del Error entre la tasa de fotosíntesis simulada por la ANN para todas las mediciones resultó ser menor (0.8532) que el valor generado como promedio de los subconjuntos de datos para entrenar la red (0.9908).

Por lo tanto, se encontró una red válida que no sobreestima el ajuste para todo el conjunto de datos, además de conservar las tendencias estadísticas resultantes después de ser entrenada.

Salazar (2010) aplicó una Red Neuronal para predecir la tasa de fotosíntesis en hojas de tomate, en la que además de las variables climáticas, se emplea como variable de entrada el vector de valores de fotosíntesis, encontrado que el desempeño de ésta se encuentra entre 97.49% y 98.77% para predicciones 5 y 10 minutos adelante. En esta investigación se logra un coeficiente de correlación de 97.56% sin emplear los datos de fotosíntesis como variable de entrada.

4.1.5 Ruta de la Fotosíntesis en función de la relación entre dos variables climáticas.

En esta sección de resultados se muestra el comportamiento de la variable respuesta Fotosíntesis contra dos variables de entrada. Los datos de entrada se toman una vez han sido filtrados por medio del Método Savitzky Golay, el vector de valores para fotosíntesis proviene de la simulación de la mejor Red Neuronal. Ésta última se explica de manera detallada en el capítulo dedicado a las Redes Neuronales Artificiales.

4.1.5.1 Fotosíntesis vs Temperatura - Concentración de CO₂

Como se observa en la Figura 4.30, las mayores tasas de fotosíntesis se obtienen cuando los rangos de temperatura se encuentran entre 25°C a 30°C. El máximo de la curva de ajuste para temperatura está situado en 27°C.

Por su parte, para los datos de entrada a la Red Neuronal, niveles de 380 ppm en la concentración del CO₂ generan las mayores tasas de fotosíntesis registradas. No obstante, al observar la superficie, se puede notar que la concentración del gas dentro del invernadero de estudio no es lo suficientemente alto para alcanzar el máximo de la función (máxima fotosíntesis), que requiere cerca de 450 ppm.




Figura 4.30) Fotosíntesis en función de las variables Temperatura y Concentración de CO₂. Arriba, superficie de la función polinomial de orden 3-2 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida:

```

Linear model Poly32:
fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2 + p30*x^3
                + p21*x^2*y + p12*x*y^2
Coefficients (with 95% confidence bounds):
p00 =      81.43  (67.04, 95.82)
p10 =     -11.2  (-12.85, -9.552)
p01 =    -0.2545 (-0.3035, -0.2056)
p20 =      0.3818 (0.3387, 0.4249)
p11 =      0.02662 (0.02179, 0.03145)
p02 =     0.0002295 (0.0001879, 0.0002711)
p30 =    -0.005186 (-0.005527, -0.004844)
p21 =   -0.0002353 (-0.0003017, -0.000169)
p12 =  -2.173e-005 (-2.521e-005, -1.825e-005)

gof =

      sse: 1.2932e+004
    rsquare: 0.9195
      dfe: 4811
  adjrsquare: 0.9194
      rmse: 1.6395

```

4.1.5.2 Fotosíntesis vs Radiación - Déficit de Presión de Vapor

En la Figura 4.31 es clara la importancia de la Radiación Fotosintéticamente Activa en el incremento de la Tasa de Fotosíntesis, puesto que a medida que la primera aumenta, la segunda lo hace también. La tasa máxima de fotosíntesis registrado (de acuerdo a la función) se alcanza aproximadamente con una radiación PAR de 230 Wm^{-2} . Sin embargo, el máximo de la función se encuentra más allá de 250 Wm^{-2} .

Por su parte, cuando el Déficit de Presión de Vapor está por arriba de 2.5 kPa, la trayectoria de la fotosíntesis no se dirige hacia el máximo de la función, por el contrario, comienza a decrecer aún para los mismos niveles de radiación PAR. Por lo tanto es importante mantener el VPD por debajo de 2.5 kPa cuando se presentan elevados niveles de radiación, para asegurar la apertura estomática y con ello, el ingreso del CO_2 al interior de las hojas.




Figura 4.31) Fotosíntesis en función de las variables PAR y VPD. Arriba, superficie de la función polinomial de orden 3-3 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida:

```

Linear model Poly33:
fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2 + p30*x^3
                + p21*x^2*y + p12*x*y^2 + p03*y^3
Coefficients (with 95% confidence bounds):
p00 =      0.1126  (0.07067, 0.1545)
p10 =      0.1717  (0.1671, 0.1762)
p01 =       1.484  (1.115, 1.853)
p20 =    -0.001701 (-0.001803, -0.001599)
p11 =         0.1  (0.08912, 0.1109)
p02 =     -3.653  (-4.221, -3.085)
p30 =    4.605e-006 (3.668e-006, 5.542e-006)
p21 =   -0.0001365 (-0.0003039, 3.09e-005)
p12 =    -0.01485  (-0.02683, -0.002858)
p03 =       0.8894  (0.5416, 1.237)

gof =

      sse: 3.7490e+003
    rsquare: 0.9767
      dfe: 4810
    adjrsquare: 0.9766
      rmse: 0.8828

```

4.1.5.3 Fotosíntesis vs Humedad Relativa - Concentración de CO₂

De la Figura 4.32 se puede ver que a medida que la Humedad Relativa se incrementa, no importando la concentración de CO₂, la tasa de fotosíntesis decrece hasta alcanzar niveles cercanos a $0 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$ cuando la HR está por encima del 90%. Esto se debe a que si la transpiración se detiene, a consecuencia de la saturación de humedad del aire, entonces lo hace también la difusión de moléculas de CO₂ hacia el interior de las hojas, afectando el proceso fotosintético de la planta (Boletín 56 FAO, 2006).

Cuando la Humedad Relativa está entre 30 y 40% se registraron las mayores tasas de fotosíntesis. Esto se debe a los altos niveles de transpiración por parte de la planta bajo esa condición de humedad relativa. De la función puede deducirse también que, cuando el nivel de HR está alrededor de 30%, no existe variación en la respuesta de la fotosíntesis con 380 ppm o 600 ppm, es decir, bajo esta condición no tendría ningún efecto enriquecer el ambiente invernadero con CO₂. Por otro lado, niveles de Humedad

Relativa por debajo de 30% (ver Figura 4.32, arriba) ocasiona el cierre estomático y, como se ve, la tasa de fotosíntesis comienza a decrecer.




Figura 4.32) Fotosíntesis en función de las variables Concentración de CO₂ y Humedad Relativa. Arriba, superficie de la función polinomial de orden 1-1 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida:

```
Linear model Poly11:
  fitresult(x,y) = p00 + p10*x + p01*y
Coefficients (with 95% confidence bounds):
  p00 =      21.25  (21.17, 21.34)
  p10 =    0.005234 (0.004966, 0.005501)
  p01 =    -0.2488 (-0.2497, -0.2479)

gof =

      sse: 1.4495e+003
    rsquare: 0.9910
      dfe: 4817
  adjrsquare: 0.9910
      rmse: 0.5486
```

4.1.5.4 Fotosíntesis vs Déficit de Presión de Vapor - Concentración de CO_2

Al observar la Figura 4. 33 puede verse claramente cómo el máximo de la función, se alcanzaría cuando el Déficit de Presión de Vapor se encuentre cercano a 3 kPa y la concentración de CO_2 por encima de 600 ppm.

Tomando en cuenta sólo los datos con que se construyó la superficie, la máxima tasa de Fotosíntesis alcanzada se produjo cuando el VPD fue de 2.5 kPa y la concentración de CO_2 de 380 ppm.

Se puede notar también que es necesario mantener niveles del Déficit de Presión de Vapor por encima de 1.5 kPa, de tal manera que se asegure la transpiración de la planta y con ello, el ingreso del dióxido de carbono al interior de ésta. Siempre y cuando se suministre suficiente agua a la raíz para favorecer el proceso de transpiración.




Figura 4.33) Fotosíntesis en función de las variables Concentración de CO_2 y VPD. Arriba, superficie de la función polinomial de orden 2-1 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida:

```

Linear model Poly21:
  fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y
Coefficients (with 95% confidence bounds):
p00 =      -3.179   (-3.364, -2.994)
p10 =       4.647   (4.235, 5.059)
p01 =      0.004835 (0.004475, 0.005195)
p20 =      -2.479   (-2.516, -2.443)
p11 =       0.0218   (0.02077, 0.02282)

```

```
gof =
```

```

      sse: 2.0590e+003
rsquare: 0.9872
      dfe: 4815
adjrsquare: 0.9872
      rmse: 0.6539

```

4.1.5.5 Fotosíntesis vs Temperatura - Humedad Relativa

De las variables climáticas más fácilmente medidas en los invernaderos, debido al bajo costo de los sensores, se encuentran la Temperatura y la Humedad Relativa. Por consiguiente, las relaciones entre estas variables y la Fotosíntesis resulta muy importante conocer.

Como se observa en la Figura 4.34, la combinación de una baja temperatura y humedad relativa altas generan tasas de Fotosíntesis bastante bajas, por debajo de $5 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$; caso contrario los niveles más altos de fotosíntesis se generan cuando la temperatura está entre los 25 – 30°C, mientras que la humedad relativa se ubica entre 30 – 40%. Puede verse también que por encima de 80% de HR independientemente de la temperatura, los niveles de fotosíntesis son muy bajos, del orden de $\frac{1}{4}$ parte de la tasa máxima registrada. Así mismo, una temperatura aceptable

mínima es 18°C, pues a partir de ella la tasa de fotosíntesis se encuentra por encima del 50% de la tasa máxima, siempre y cuando la HR se tenga valores del 30 al 65%.




Figura 4.34) Fotosíntesis en función de las variables Humedad Relativa y Temperatura. Arriba, superficie de la función polinomial de orden 2-2 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida:

```

Linear model Poly22:
  fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2
Coefficients (with 95% confidence bounds):
p00 =      -3.288  (-5.87, -0.7068)
p10 =       1.102  (0.9739, 1.231)
p01 =       0.3023 (0.2602, 0.3443)
p20 =      -0.01365 (-0.0153, -0.01199)
p11 =     -0.009808 (-0.01081, -0.008803)
p02 =     -0.002827 (-0.003006, -0.002649)

```

```
gof =
```

```

      sse: 2.7755e+003
rsquare: 0.9829
   dfe: 4814
adjrsquare: 0.9829
    rmse: 0.7593

```

4.2 INVERNADEROS EXPERIMENTALES DE LA DIVISIÓN DE INGENIERÍA EN BIOSISTEMAS, UNIVERSIDAD HUMBOLDT DE BERLÍN.

En los siguientes apartados se muestran los resultados obtenidos al procesar los datos tomados en los Invernaderos experimentales de la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín, Alemania. Como se explicó en la sección de Materiales y Métodos, las mediciones efectuadas se dividen en dos grandes conjuntos, de acuerdo al tipo de tecnología empleada para el acondicionamiento de las variables climáticas: las hechas al Sistema Convencional y las del Sistema de Neblina Descendente (Des-Fog). Por lo tanto, a lo largo de esta sección se les tratará de manera independiente.

Se explican al principio, en la sección 4.2.1 las diferentes variables climáticas medidas, así como su relación con la Tasa de Fotosíntesis. Enseguida, en la sección 4.2.2 se aplica la *Teoría de Identificación de Sistemas* para encontrar un Modelo Matemático que prediga satisfactoriamente la tasa de Fotosíntesis Foliar, teniendo como base cinco variables climáticas de entrada. En la sección 4.2.3 se presenta la adaptación y calibración de la *Sub-rutina del Modelo SUCROS* para simular la tasa de fotosíntesis efectuadas por las plantas de tomate del experimento. Posteriormente en la sección 4.2.4, se presentan las *Redes Neuronales* que describen el proceso de Fotosíntesis para cada sistema estudiado. Finalmente, se explica el efecto de la interrelación de dos variables climáticas en la tasa de Fotosíntesis, esto en la sección 4.2.5.

4.2.1 Comportamiento de las variables climáticas que afectan la fotosíntesis.

4.2.1.1 Fotosíntesis vs Radiación

El valor máximo registrado por el sensor del PTM-48 para la Radiación Fotosintéticamente Activa (PAR), durante los 99 días de muestreo, fue de 192 Wm^{-2} . Puede verse en la Figura 4.35 cómo a medida que se da la elevación solar, las hojas de tomate comienzan con el proceso fisiológico de la fotosíntesis.

Únicamente se presenta la información de un sensor de radiación, debido a que las dos naves de las que se obtuvieron mediciones de fotosíntesis tienen la misma orientación y características estructurales, además de estar en una posición contigua una de la otra; por lo tanto, se considera que el valor reportado para esta variable climática es el mismo, tanto para el invernadero con sistema convencional como para el de sistema Des-Fog.




Figura 4.35) Fotosíntesis vs Radiación PAR durante los días Julianos 253-255.

Las horas del día con radiación suman aproximadamente 12 para los días julianos que se muestran en la Figura 4.35 (cercanos al inicio del experimento); sin embargo, debido a la latitud en que se encuentran los invernaderos de experimentación ($52^{\circ} 28'N$), a medida que se avanza en los días, esta situación es diferente (Figura 4.36), llegando a tener solamente 8 horas de radiación PAR por día, y niveles máximos de ésta apenas cercanos a 20 Wm^{-2} al final del experimento (día Juliano 329).




Figura 4.36) Trayectoria de la Radiación Fotosintéticamente Activa a lo largo del periodo de mediciones.

Aunado a los niveles bajos de radiación, debidos a la latitud en que se ubica el sitio de experimentación, existe una disminución muy drástica en la cantidad de PAR que está disponible para las plantas de tomate, esto se debe a las sombras que generan, por un lado, la estructura (acero y cubierta de vidrio) del invernadero y por el otro, el sistema de automatización del mismo (motores, reductores, flechas, cableado que conforman el sistemas de apertura y cierre de ventanas cenitales), tal como puede apreciarse en las Figuras 4.37 y 4.38. En la primera se encuentran señaladas mediante flechas las sombras más representativas en la curva de la radiación a lo largo de un día.

En la segunda Figura, se muestra cómo para un mismo lapso de tiempo, existen zonas dentro del invernadero con más de 100 Wm^{-2} , mientras que en otras se está por debajo de 50 Wm^{-2} de Radiación Fotosintéticamente Activa. Esta condición de baja intensidad de radiación PAR al interior del invernadero, explica las tasas de fotosíntesis que son generalmente bajas en comparación con las medidas en los invernaderos de Querétaro.




Figura 4.37) Comportamiento de la Radiación Fotosintéticamente Activa al interior del invernadero durante un día. Es clara la influencia de la estructura en la generación de sombras.




Figura 4.38) Distribución de la Radiación Fotosintéticamente Activa en la superficie del invernadero, durante un lapso de 1 hora en 140 puntos de medición.

4.2.1.2 Fotosíntesis vs Temperatura

Como se explicó en la sección de Materiales y Métodos, existen dos formas para controlar la temperatura al interior del invernadero; la primera se da al activar el Sistema de Des-Fog cuando la temperatura supera los 23°C, y detenerlo cuando se llega al 80% de Humedad Relativa; o bien, con el Sistema Convencional de apertura y cierre de ventanas, que opera también a partir de los 23°C. Debido al sistema de control automático es que las curvas de la Temperatura tienen las características mostradas en la Figura 4.39. Por un lado, la temperatura en el sistema Des-Fog se logra mantener como una constante en aproximadamente 26°C durante las horas de fotosíntesis; mientras que en el sistema convencional las fluctuaciones son más notorias, y dependen en gran medida de la temperatura del aire al exterior del invernadero.




Figura 4.39) Fotosíntesis vs Temperatura durante los días Julianos 253-255.

En ambos invernaderos, la velocidad con que pierden carga térmica es lenta debido a que las paredes y cubiertas son de vidrio (coeficiente de conducción = 5.85

[$\text{kcal m}^{-2} \text{h}^{-1} \text{C}^{-1}$], coeficiente de permeabilidad = 0.04) y las ventanas sellan perfectamente al estar cerradas, reduciendo con ello las pérdidas de calor por conducción, radiación y filtración.

Durante el periodo de tiempo estudiado, las temperaturas máxima y mínima del Sistema Des-Fog fueron: 32.23°C y 15.35°C , respectivamente. Para el Sistema Convencional la temperatura máxima es: 36.27°C , mientras que la mínima es de: 15.4°C . Las temperaturas mínimas son muy parecidas, pues el sistema de calefacción opera en ambos invernaderos con idéntico algoritmo de control. El mejor control de la variable temperatura se obtuvo con el Sistema Des-Fog.

4.2.1.3 Fotosíntesis vs Humedad Relativa

En el Sistema Convencional, tal como se aprecia en la Figura 4.40, las variaciones en la Humedad Relativa a lo largo del día son amplias, con diferencia entre el día y la noche de más de 60%. El valor máximo de esta variable al interior del invernadero durante los días de estudio es de: 100%, mientras que el mínimo es 19.4%.

Para el Sistema Des-Fog el valor máximo también es 100%, mientras que el mínimo es de 31.68%. Sin embargo, debido al constante suministro de partículas de agua para reducir la temperatura, las fluctuaciones de esta variable son más pequeñas que en el Sistema Convencional, encontrándose en el rango del 60 – 90%. En la Figura 4.40, se muestra cómo la humedad relativa se mantiene dentro de un rango muy pequeño (70-90%) cuando el sistema Des-Fog se encuentra funcionando. Esta situación provoca una saturación del aire con agua, generando una disminución en las tasa de del transpiración del follaje y como consecuencia, disminuye la actividad fotosintética

(Boletín 56 FAO, 2006) en el sistema Des-Fog, en contraste con el sistema Convencional en donde se registran valores más altos de fotosíntesis.




Figura 4.40) Fotosíntesis vs Humedad Relativa durante los días Julianos 253-255.

4.2.1.4 Fotosíntesis vs Concentración de CO₂

A pesar de que se mantiene una inyección constante de dióxido de carbono al interior de ambos invernaderos, según se explicó en la sección de Materiales y Métodos, puede observarse en la Figura 4.41 la influencia del cultivo en la reducción de la concentración de este gas durante las horas en que las plantas realizan el proceso de la fotosíntesis. La mayor tasa de fotosíntesis para los días graficados, la presenta el Sistema Convencional, pues como ya se explicó en el apartado anterior, las condiciones de humedad son mejores que en el Sistema Des-Fog. Consecuentemente, el nivel de CO₂ al interior de ese invernadero es mucho menor que en el de Sistema Des-Fog; esto se debe a que, a mayor tasa de fotosíntesis, la concentración del CO₂ disminuye proporcionalmente.

Resulta interesante de la Figura 4.41, cómo durante la noche, las plantas en el Sistema Des-Fog, no aportan mucho del gas a consecuencia del proceso de respiración, manteniéndose la concentración durante la noche en aproximadamente 500 ppm. Situación diferente se presenta en el invernadero Convencional, en el que es muy clara la aportación de dióxido de carbono durante la noche, pasando de 370 ppm a cerca de 600 ppm antes de realizar el enriquecimiento del día siguiente.




Figura 4.41) Fotosíntesis vs Concentración de CO_2 durante los días Julianos 253-255.

Durante un día de mediciones cualquiera, se notan 2 puntos muy importantes en cada curva del nivel de CO_2 , al interior de los invernaderos, ya sea Sistema Convencional o Des-Fog (Figura 4.42); el primero (puntos A y B) representa el punto en el que la velocidad de asimilación del gas, por parte de las hojas de las plantas, se incrementa por encima de $3 \mu\text{mol CO}_2/\text{m}^2\cdot\text{s}^{-1}$ y corresponde también al punto en que la temperatura al interior del invernadero supera los 23°C para ese día específico. El segundo punto se presenta cuando la concentración del dióxido de carbono comienza a

incrementarse (recordar que el proceso de enriquecimiento se detiene hasta las 5:15pm) debido a una disminución drástica en la actividad fotosintética, puntos C y D.

La concentración máxima de CO₂ para el Sistema Convencional es 1014 ppm, mientras que la mínima es 325.1 ppm. Para el Sistema Des-Fog la máxima concentración del gas al interior del invernadero es 992.2 ppm, la más baja es 312.8 ppm.




Figura 4.42) Concentración de CO₂ al interior de los invernaderos para el día Juliano 253.

4.2.1.5 Fotosíntesis vs Déficit de Presión de Vapor

El Déficit de Presión de Vapor (VPD, por sus siglas en inglés) afecta indirectamente, como se explicó en el apartado 4.1.1.5, la apertura estomática y con ello la cantidad de CO₂ que ingresa al interior de las estructuras foliares para efectuar la fotosíntesis.

Debido a los sistemas de control de la temperatura y humedad relativa al interior de cada uno de los invernaderos estudiados, los niveles del VPD se mueven en un margen muy amplio (Figura 4.43). Por un lado, los niveles para el Sistema Convencional están entre cero y 4.59 kPa, mientras que para el Sistema Des-Fog están entre cero y 3.312 kPa; sin embargo, para los días en que la radiación no es muy alta, el nivel del Déficit de Presión de Vapor para ambos invernaderos se mueve de cero a un kPa.




Figura 4.43) Fotosíntesis vs Déficit de Presión de Vapor durante los días Julianos 253-255.

Al analizar por separado cada una de las cinco variables climáticas arriba expuestas es claro que no es posible encontrar una relación directa entre cada una de ellas y la tasa de fotosíntesis medida. Esto se debe a que el comportamiento de este proceso fisiológico es altamente no lineal y depende de todas las variables (Figura 4.44) para ser descrito con precisión. Las líneas en color rojo son las variables climáticas que explican el comportamiento de la fotosíntesis en el Sistema Convencional; las de color azul, describen al Des-Fog. La curva de radiación es la misma para ambos sistemas como ya se explicó.

La tasa de fotosíntesis más alta se encontró en el Sistema convencional, con $11.19 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$, mientras que la máxima del Sistema Des-Fog fue de $9.35 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$.




Figura 4.44) Variables climáticas que afectan el proceso de Fotosíntesis. De arriba hacia abajo, Tasa de Fotosíntesis, Temperatura, Humedad Relativa, Concentración de CO₂, Déficit de Presión de Vapor y, Radiación PAR.

4.2.2 Metodología de la Identificación de Sistemas aplicada a Fotosíntesis.

De las evaluaciones, los Modelos Dinámicos no Lineales de Autoregresión con Variables Exógenas (nlARX), incluso los ARX lineales mostraron los mejores desempeños comparados con modelos como los Auto-regresivos con Promedio Móvil y Entradas Exógenas (ARMAX), Box-Jenkins (BJ) y Error de la salida (OE). Sin embargo, a diferencia de los resultados obtenidos en la sección 4.1.2, los mejores ajustes obtenidos, después de realizar 10^{11} evaluaciones de modelos, se encuentran por debajo de 30% (Figura 4.45) para datos tanto del Sistema Des-Fog como del Convencional; lo anterior se debe principalmente al tiempo de muestreo (5min), que se reduce a la mitad con respecto de los datos de Querétaro (10min), así como a la cantidad de información procesada, que en este caso, es 4.6 veces mayor. Por lo tanto, puede verse que los modelos de caja negra evaluados no son capaces de explicar la trayectoria de la fotosíntesis, a partir de cinco variables de entrada: 1) Radiación, 2) Temperatura, 3) Humedad Relativa, 4) Déficit de Presión de Vapor y, 5) Concentración de CO_2 .




Figura 4.45 Ajuste de los mejores modelos de caja negra para el Sistema Convencional.

4.2.3 Modelo Mecanicista de Goudriaan para predicción de la Fotosíntesis Foliar.

De los parámetros que considera el Modelo Mecanicista de Goudriaan, contenido en la subrutina del Modelo SUCROS (Simple and Universal Crop Simulator) para calcular la fotosíntesis foliar, tanto Latitud como A_{max} (Tasa máxima de fotosíntesis), se consideran constantes. La ubicación de los Invernaderos en Dahlem, Berlín, Alemania es $52^{\circ}28'$ Latitud Norte (52.46); las tasas máximas de fotosíntesis tanto para Sistema Convencional, como para Sistema Des-Fog son $0.4924 \text{ [mgCO}_2\text{m}^{-2}\text{s}^{-1}]$ y $0.4117 \text{ [mgCO}_2\text{m}^{-2}\text{s}^{-1}]$, respectivamente (ver Figura 4.46).




Figura 4.46) La tasa máxima de fotosíntesis (A_{max}) es un parámetro medido a lo largo de los días de estudio. Arriba, A_{max} Sistema Convencional; Abajo, A_{max} Sistema Des-Fog.

El parámetro Índice de Área Foliar (LAI, por sus siglas en inglés, tal como aparece en el modelo) se toma como la unidad, puesto que se debe comparar la fotosíntesis registrada por el Fitomonitor PTM-48 que tiene unidades en $[\text{mgCO}_2\text{m}_h^{-2}\text{s}^{-1}]$, contra las predicciones de la sub-rutina del Modelo SUCROS, con unidades en $[\text{mgCO}_2\text{m}_s^{-2}\text{s}^{-1}]$. La deducción para tomar $\text{LAI} = 1$ se explicó en el capítulo 4.1.3.

Los parámetros: Coeficiente de Dispersión de las Hojas para PAR, **SCP** (adimensional); Coeficiente de Extinción de la Radiación, **KDF** (adimensional); Eficiencia del Uso de la Radiación, **EFF** $[\text{mgCO}_2\text{J}^{-1}]$; así como el Coeficiente de Transmisitividad Atmosférica, **ATMTR** (adimensional), se calibraron para un día y 4 días de mediciones, tanto para Fotosíntesis (Convencional y Des-Fog) únicamente, como para la relación Fotosíntesis-Radiación PAR. Para esta última relación, la calibración de la Radiación se realizó entre la PAR registrada por el sensor, y la salida $y(6)$ del modelo, que es la Radiación Fotosintéticamente Activa Teórica disponible al interior del invernadero. En el Cuadro 12 se presentan los diferentes valores propuestos como semilla para cada calibración. En los Cuadros 13 al 20 se presentan los valores obtenidos para cada parámetro, según el tipo de sistema, Convencional o Des-Fog.

Cuadro 12. Valores semilla propuestos para cada una de las 10 calibraciones.

Parámetro	1	2	3	4	5	6	7	8	9	10	Incremento
SCP	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.999	0.100
KDF	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.999	0.100
EFF	0.001	0.006	0.012	0.017	0.023	0.028	0.034	0.039	0.045	0.050	0.005
ATMTR	0.125	0.181	0.236	0.292	0.347	0.403	0.458	0.514	0.569	0.625	0.056

Los límites extremos para cada parámetro se proponen de acuerdo a Goudriaan & Van Laar, 1994. El límite superior para ATMTR considera la pérdida de transmisitividad a causa de la cubierta del Invernadero.

Cuadro 13. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Convencional.

PARÁMETROS CALIBRADOS - CONVENCIONAL [FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.1	0.1995	0.2952	0.5376	0.6531	0.8017	0.9577	0.9577	0.9577	0.964
KDF	0.1768	0.2990	0.2971	0.3072	0.2721	0.3665	0.1001	0.1000	0.1001	0.1002
EFF	0.0242	0.0126	0.0131	0.0143	0.0178	0.0161	0.0384	0.0384	0.0385	0.047
ATMTR	0.1763	0.2187	0.2199	0.2208	0.2142	0.2215	0.5854	0.5852	0.5837	0.5067
R2*	0.9206	0.9205	0.9205	0.9205	0.9205	0.9205	0.9402	0.9402	0.9402	0.9396
CME * (E-04)	9.3788	9.3838	9.3837	9.3842	9.3824	9.3877	6.9012	6.9013	6.9011	6.9787
RCME*	0.0306	0.0306	0.0306	0.0306	0.0306	0.0306	0.0263	0.0263	0.0263	0.0264
R2+	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547
CME+	733.02	876.79	884.83	890.54	849.24	895.61	12951	12941	12851	8721.2
RCME+	27.074	29.611	29.746	29.842	29.142	29.927	113.80	113.76	113.36	93.387

(*) Fotosíntesis (+) PAR

Cuadro 14. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Convencional.

PARÁMETROS CALIBRADOS -CONVENCIONAL [PAR & FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.4009	0.1783	0.2765	0.4660	0.6269	0.7151	0.7634	0.8286	0.8821	0.9552
KDF	0.3555	0.2978	0.2893	0.3058	0.3302	0.3481	0.3400	0.3819	0.3976	0.5262
EFF	0.0149	0.0156	0.0168	0.0174	0.0182	0.0189	0.0206	0.0209	0.0224	0.027
ATMTR	0.174	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.174
R2*	0.9205	0.9206	0.9205	0.9205	0.9205	0.9205	0.9205	0.9205	0.9207	0.9204
CME*(E-04)	9.3910	9.4100	9.3833	9.3841	9.3855	9.3888	9.3860	9.3887	9.4936	9.4002
RCME*	0.0306	0.0307	0.0306	0.0306	0.0306	0.0306	0.0306	0.0306	0.0308	0.0307
R2+	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547
CME+	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63
RCME+	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067

(*) Fotosíntesis (+) PAR

Cuadro 15. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Convencional.

PARÁMETROS CALIBRADOS -CONVENCIONAL [FOTOSINTESIS]										
4 DIAS	1	2	3	4	5	6	7	8	9	10
SCP	0.1	0.1957	0.2878	0.5079	0.6214	0.6739	0.7306	0.9721	0.9722	0.9973
KDF	0.1952	0.3169	0.3123	0.3325	0.2817	0.2523	0.2442	0.3190	0.3228	0.9815
EFF	0.0255	0.0140	0.0145	0.0153	0.0190	0.0218	0.0240	0.0347	0.0345	0.050
ATMTR	0.1782	0.2176	0.2205	0.2198	0.2202	0.2217	0.2203	0.2909	0.2907	0.262
R2*	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7517	0.7517	0.7517
CME*(E-03)	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90
RCME*	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.6269
R2+	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	1385.2
CME+	659.78	878.33	902.74	896.77	900.09	913.17	901.06	1862.8	1859.6	37.219
RCME+	25.686	29.637	30.046	29.946	30.001	30.219	30.018	43.160	43.123	37.219

(*) Fotosíntesis (+) PAR

Cuadro 16. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Convencional.

PARÁMETROS CALIBRADOS -CONVENCIONAL [PAR & FOTOSINTESIS]										
4 DIAS	1	2	3	4	5	6	7	8	9	10
SCP	0.3577	0.1710	0.2664	0.4197	0.5764	0.6744	0.7464	0.7925	0.8614	0.9922
KDF	0.3934	0.3195	0.3372	0.3685	0.3580	0.3863	0.4082	0.4093	0.4612	0.9591
EFF	0.017	0.0188	0.0184	0.0184	0.0206	0.0211	0.0218	0.0231	0.0245	0.050
ATMTR	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603
R2*	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7513	0.7510
CME*(E-03)	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90	3.90
RCME*	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0625	0.0626
R2+	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269
CME+	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41
RCME+	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148

(*) Fotosíntesis (+) PAR

Cuadro 17. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Des-Fog.

PARÁMETROS CALIBRADOS -DES-FOG [FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.2835	0.1130	0.1701	0.2332	0.3636	0.4361	0.4660	0.9919	0.9916	0.9943
KDF	0.2044	0.1883	0.2026	0.2030	0.2062	0.1898	0.1934	0.9568	0.9651	0.9989
EFF	0.0355	0.0360	0.0343	0.0350	0.0364	0.0405	0.0405	0.0410	0.0398	0.050
ATMTR	0.2204	0.2211	0.2209	0.2207	0.2204	0.2207	0.2205	0.4139	0.4172	0.3897
R2*	0.9316	0.9316	0.9316	0.9316	0.9316	0.9316	0.9316	0.9789	0.9789	0.9789
CME*(E-03)	1.90	1.90	1.90	1.90	1.90	1.90	1.90	0.53	0.53	0.53
RCME*	0.0432	0.0432	0.0432	0.0432	0.0432	0.0432	0.0432	0.023	0.023	0.023
R2+	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547
CME+	888.0	893.1	891.4	890.2	888.2	890.4	888.8	4888.2	5001.3	4090.5
RCME+	29.800	29.885	29.856	29.837	29.803	29.840	29.813	69.916	70.720	63.957

(*) Fotosíntesis (+) PAR

Cuadro 18. Calibraciones del día Juliano 231 (19 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Des-Fog.

PARÁMETROS CALIBRADOS -DES-FOG [PAR & FOTOSINTESIS]										
1 DIA	1	2	3	4	5	6	7	8	9	10
SCP	0.2845	0.1623	0.2061	0.2571	0.3647	0.5057	0.5014	0.6184	0.5470	0.9793
KDF	0.4631	0.4370	0.3185	0.3241	0.3042	0.3719	0.3280	0.3921	0.3107	0.999
EFF	0.0227	0.0226	0.0299	0.0297	0.0330	0.0299	0.0330	0.0309	0.0357	0.050
ATMTR	0.174	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.1740	0.174
R2*	0.9307	0.9311	0.9311	0.9315	0.9312	0.9311	0.9314	0.9312	0.9311	0.9276
CME*(E-03)	1.90	1.90	1.90	1.90	1.90	1.90	1.90	1.90	1.90	2.00
RCME*	0.0435	0.0434	0.0433	0.0433	0.0433	0.0434	0.0433	0.0434	0.0433	0.0445
R2+	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547	0.6547
CME+	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63	732.63
RCME+	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067	27.067

(*) Fotosíntesis (+) PAR

Cuadro 19. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para la Variable de salida Fotosíntesis. Sistema Des-Fog.

4 DIAS	PARÁMETROS CALIBRADOS -DES-FOG [FOTOSINTESIS]									
	1	2	3	4	5	6	7	8	9	10
SCP	0.402	0.1818	0.2656	0.4454	0.5370	0.6186	0.6799	0.9954	0.9960	0.9971
KDF	0.2488	0.2371	0.2597	0.2545	0.2079	0.2304	0.2365	0.9950	0.9921	0.999
EFF	0.0208	0.0200	0.0189	0.0208	0.0262	0.0253	0.0258	0.0389	0.0421	0.050
ATMTR	0.2181	0.2176	0.2180	0.2182	0.2186	0.2186	0.2212	0.2975	0.2943	0.2879
R2*	0.7941	0.7942	0.7941	0.7941	0.7942	0.7942	0.7942	0.7965	0.7965	0.7965
CME*(E-03)	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.10	3.10	3.10
RCME*	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0559	0.0559	0.0559
R2+	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269
CME+	882.49	878.06	881.33	883.04	886.17	886.51	908.95	1990.1	1928.2	1808.3
RCME+	29.707	29.632	29.687	29.716	29.769	29.774	30.149	44.611	43.911	42.525

(*) Fotosíntesis (+) PAR

Cuadro 20. Calibraciones de los días Julianos 234 al 237 (22-25 de Agosto de 2009) para las Variables de salida Fotosíntesis y PAR. Sistema Des-Fog.

4 DIAS	PARÁMETROS CALIBRADOS -DES-FOG [PAR & FOTOSINTESIS]									
	1	2	3	4	5	6	7	8	9	10
SCP	0.3249	0.1741	0.2603	0.3925	0.5517	0.6618	0.7286	0.8338	0.8404	0.9905
KDF	0.4097	0.3993	0.3581	0.3305	0.3702	0.3795	0.4008	0.4569	0.4666	0.999
EFF	0.018	0.0174	0.0195	0.0221	0.0219	0.0234	0.0241	0.0256	0.0256	0.050
ATMTR	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603	0.1603
R2*	0.7941	0.7941	0.7941	0.7941	0.7941	0.7941	0.7941	0.7941	0.794	0.7934
CME*(E-03)	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20
RCME*	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0562	0.0563
R2+	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269	0.6269
CME+	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41	632.41
RCME+	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148	25.148

(*) Fotosíntesis (+) PAR

En los Cuadros 21 y 22 se presentan las mejores calibraciones de la Sub-rutina del Modelo SUCROS para el Sistema Convencional y Des-Fog, respectivamente. La selección se realizó siguiendo la metodología explicada en la sección 4.1.3.

Para el Sistema Convencional (Cuadro 21), no se encontraron diferencias significativas para la calibración a un día con la variable fotosíntesis únicamente o empleado la relación fotosíntesis y PAR (diferencia entre uno y otro =0.0001). El ajuste entre la fotosíntesis medida y la calculada por el Modelo es del 92% en ambos casos,

mientras que el ajuste en la PAR es del 65.47%. Situación similar sucede con las calibraciones a cuatro días, siendo ligeramente mejor la reportada en la columna cuarta del cuadro, pues la raíz del cuadrado medio del error para PAR es menor que si se considerara solo una variable durante las iteraciones.

La mejor calibración para 4 días alcanza un **75.13%** de ajuste para la variable fotosíntesis y **62.69%** de ajuste para PAR, 16.92% y 2.78% menos que los valores reportados para la calibración a un día. A pesar de ello, se consideran como mejores parámetros del modelo los de la cuarta columna del Cuadro 21 ([SCP KDF EFF ATMTR]=[0.2664 0.3372 0.0184 0.1603]) puesto que caracterizan de forma más general el comportamiento de la Sub-rutina del Modelo SUCROS sobre el conjunto de datos. Si se eligieran los parámetros de la calibración de un día, el modelo estaría sobreestimado.

Cuadro 21. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis. Sistema Convencional.

Parámetro	1 DIA Fotosíntesis	1 DIA Foto & PAR	4 DIAS Fotosíntesis	4 DIAS Foto & PAR
SCP	0.1	0.2765	0.1	0.2664
KDF	0.1768	0.2893	0.1952	0.3372
EFF	0.0242	0.0168	0.0255	0.0184
ATMTR	0.1763	0.1740	0.1782	0.1603
R2*	0.9206	0.9205	0.7513	0.7513
CME*	9.3788E-04	9.3833E-04	3.90E-03	3.90E-03
RCME*	0.0306	0.0306	0.0625	0.0625
R2+	0.6547	0.6547	0.6269	0.6269
CME+	733.02	732.63	659.78	632.41
RCME+	27.074	27.067	25.686	25.148

(*) Fotosíntesis (+) PAR

Para el Sistema Des-Fog (Cuadro 22) los mejores parámetros, tomando en cuenta el cuadrado medio del error, se encuentran en las columnas segunda y cuarta, y

corresponden a las calibraciones en que se consideraron las variables Fotosíntesis y PAR para realizar el proceso de iteraciones.

El mejor ajuste se obtiene usando los parametros resultantes de la calibración a un día, sin embargo, como ya se explicó, usarlos significa tener un modelo sobreajustado y que no describe la tendencia de todo el conjunto de datos. Los parámetros **[SCP KDF EFF ATMTR]=[0.3249 0.4097 0.0180 0.1603]** de la columna número cuatro del Cuadro 22, caracterizan de manera global el comportamiento de la Sub-rutina del Modelo SUCROS sobre el conjunto de datos del Sistema Des-Fog, con un ajuste del **79.41%** en la variable Fotosíntesis y del **62.69%** para la Radiación Fotosintéticamente Activa.

Cuadro 22. Mejores calibraciones para la subrutina del Modelo SUCROS aplicada a datos de fotosíntesis. Sistema Des-Fog.

Parámetro	1 DIA Fotosíntesis	1 DIA Foto & PAR	4 DIAS Fotosíntesis	4 DIAS Foto & PAR
SCP	0.1701	0.2571	0.1818	0.3249
KDF	0.2026	0.3241	0.2371	0.4097
EFF	0.0343	0.0297	0.0200	0.018
ATMTR	0.2209	0.1740	0.2176	0.1603
R2*	0.9316	0.9315	0.7942	0.7941
CME*	1.90E-03	1.90E-03	3.20E-03	3.20E-03
RCME*	0.0432	0.0433	0.0562	0.0562
R2+	0.6547	0.6547	0.6269	0.6269
CME+	891.4	732.63	878.06	632.41
RCME+	29.856	27.067	29.632	25.148

(*) Fotosíntesis (+) PAR

Al comparar los parámetros generados para los Sistemas Convencional y Des-Fog, se encuentra que el valor de la Eficiencia del Uso de la Radiación, **EFF** [$\text{mgCO}_2\text{J}^{-1}$], así como el Coeficiente de Transmisitividad Atmosférica, **ATMTR** (adimensional), son los mismos para ambos Sistemas: **0.018** y **0.1603**, respectivamente. Lo anterior se debe a

que, en ambos sistemas (Convencional y Des-Fog) se tiene el mismo cultivo, tomate, y la EFF es una característica propia de cada especie vegetal; además, ambos tipos de invernaderos tienen las mismas características estructurales, por lo tanto, la transmisividad de la radiación en ambos es la misma, pues se encuentran ubicados en una posición contigua.

Al comparar los valores de EFF para los datos de los Invernaderos de Dahlem, Berlin, Alemania (Convencional= 0.0184, Des-Fog=0.0180) con el valor del mismo parámetro para los datos de Querétaro, México (EFF=0.0183), **se encuentra que para el cultivo de tomate (*Lycopersicon esculentum mill.*), la EFF es de $0.0180^{+0.0004}_{-0.0}$ [mgCO₂J⁻¹].**

Los parámetros SCP y KDF, varían entre uno y otro sistema, pues dependen de la posición de las cámaras del Fitomonitor PTM-48 en el dosel de cada planta muestreada, además de las variaciones en crecimiento vegetativo de las plantas, según las condiciones del microclima de cada invernadero.

En las siguientes Figuras se observa el comportamiento de la sub-rutina del modelo SUCROS para predecir la tasa de Fotosíntesis del Sistema Convencional (Figuras 4.47 y 4.48) y del Sistema Des-Fog (Figuras 4.49 y 4.50). La comparación entre la Radiación Fotosintéticamente Activa dentro del invernadero, entre datos medidos (es lo mismo para los sistemas Convencional y Des-Fog, como ya se explicó líneas arriba) y los simulados por SUCROS, se presentan en las Figuras 4.51 y 4.52.




Figura 4.47) Fotosíntesis Teórica vs Medida para los días Julianos 234-237. Sistema Convencional.




Figura 4.48) Regresión para Fotosíntesis en los días Julianos 234-237. Sistema Convencional.




Figura 4.49) Fotosíntesis Teórica vs Medida para los días Julianos 234-237. Sistema Des-Fog.




Figura 4.50) Regresión para Fotosíntesis en los días Julianos 234-237. Sistema Des-Fog.




Figura 4.51) Radiación PAR medida por el sensor dentro del invernadero vs PAR teórica. Días Julianos 234-237, aplica a ambos sistemas.




Figura 4.52) Regresión para Radiación Fotosintéticamente Activa Disponible en los días Julianos 234-237.

Como puede verse en las Figuras anteriores, el grado de ajuste del modelo ya calibrado es aceptable, más no ideal. Esto se debe a que el Modelo Mecanicista de Goudriaan, contenido en la Subrutina del Modelo SUCROS, que calcula la tasa de

fotosíntesis foliar, lo hace en *función de la elevación solar* para un día Juliano dado. El modelo solo toma la cantidad de radiación PAR disponible, así como parámetros que solo definen su impacto sobre el dosel (SCP, KDF, EFF, ATMTR), como única variable que influye en el comportamiento de la fotosíntesis foliar, dejando a un lado el resto de variables climáticas tales como temperatura, humedad relativa y nivel de CO₂.

A pesar de estar contenido el parámetro de la transmisibilidad atmosférica (ATMTR) en la subrutina del modelo SUCROS, éste no es capaz de describir en su totalidad el curso de la radiación PAR a lo largo del día, pues, como se ve en la Figura 4.51, el efecto del paso esporádico de nubes sobre el área de estudio no está contemplado, así como las sombras generadas por la estructura de cada invernadero, tal como se explicó en la sección 4.2.1.1.

Finalmente en la Figura 4.53 se presenta la Simulación del Modelo Sucros para la declinación de la tasa de fotosíntesis en función del día del año y la hora del día, para los 99 días de Mediciones realizadas en Berlín, Alemania. Cada curva representa un día, al graficar todas en un sola Figura parece que forman una superficie. Puede observarse que la tasa de fotosíntesis disminuye tanto en intensidad [$\text{mgCO}_2\text{m}^{-2}\text{s}^{-1}$] como en duración a lo largo de las horas del día. Como ya se explicó, la sub-rutina del modelo SUCROS está basada en la cantidad de radiación absorbida por el dosel; por lo tanto, debido a la latitud en que se encuentran los invernaderos de investigación que hace que la duración de las horas con radiación pase de más de 12 horas por día (para el día Juliano 231) a sólo 8 horas a fines de Noviembre (día Juliano 329), la tasa de fotosíntesis estimada por el Modelo se reduce proporcionalmente.




Figura 4.53) La declinación de la Fotosíntesis está en función de la elevación solar a través del tiempo. Se grafica para los días 231 al 329, sistema Convencional.

4.2.4 Redes Neuronales Aplicadas al Sistema Fotosíntesis.

Se evaluaron diferentes configuraciones de Redes Neuronales Artificiales (ANN por sus siglas en inglés, Artificial Neural Networks) para predecir la tasa de fotosíntesis de los Sistemas Convencional y Des-Fog, en función de 5 variables climáticas medidas al interior de cada invernadero: 1) Radiación, 2) Temperatura, 3) Humedad Relativa, 4) Déficit de Presión de Vapor y, 5) Concentración de CO_2 . La diferencia entre las configuraciones de la ANN probadas, radica en su estructura (número de capas que las integran y, número de neuronas en cada capa), así como el origen de los datos de entrenamiento, directos de los sensores o filtrados.

El tipo de red para los análisis fue en todos los casos de Retro-propagación (Feed-Forward Back-Propagation), con función de entrenamiento Levenberg-Marquardt (TRAINLM); función de aprendizaje por Gradiente descendente con momento

(LEARNGDM); función de desempeño, Cuadrado Medio de Error (MSE, por sus siglas en inglés, Mean Squared Error); función de transferencia, Hiperbólica Tangente Sigmoidal (TANSIG) para las capas ocultas y función de transferencia lineal (PURELIN) para la capa de salida. Lo anterior se debe a que, si en la capa de salida se emplean neuronas Sigmoidales, la salida de la red se limita a un rango muy pequeño; por el contrario, al usar una neurona lineal, la salida puede tomar cualquier valor.

Después de varios procesos de iteración, se toman como Redes válidas, aquellas en las que el grado de ajuste del modelo tanto en validación como en prueba, es menor que en estimación, en caso contrario, se obtendría una Red Neuronal que sobreestima los datos. Las mejores Redes Neuronales para el Sistema Convencional y Des-Fog, tanto para datos no filtrados como para los filtrados, se presentan en los Cuadros 23 al 28).

Cuadro 23. Estadísticos de las mejores configuraciones de red para los datos no filtrados. Sistema Convencional.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	85.74	86.315	87.288	R2
	1.0619	1.067	0.96318	CME
3	5,5	10,5	15,5	*
	85.994	87.288	88.116	R2
	1.0451	0.90682	0.87231	CME
	5,10	10,10	15,10	*
	86.548	88.382	88.455	R2
	1.0476	0.8513	0.89198	CME
	5,15	10,15	15,15	*
	87.232	88.786	89.371	R2
	0.9276	0.90013	0.90059	CME

(*) Número de neuronas en las capas ocultas.

El mejor desempeño para los datos no procesados por el Filtro Savitzky Golay, tomando en cuenta el cuadrado medio del error, lo presenta Red de 3 capas con una combinación de 10-10 neuronas en las capas ocultas; para esta red el ajuste entre los

valores medidos con los simulados por la ANN es de **88.382%**, con un CME igual a 0.8513. Del Cuadro 23 puede verse que el ajuste que da la arquitectura de red de 3 capas, 15-15 neuronas, es 1% mayor al descrito arriba, sin embargo, considerando el valor de su CME (0.90059), su desempeño es mucho menor.

La arquitectura de 4 capas con una configuración de 15-15-15 neuronas en las capas ocultas, reporta el mejor desempeño para los datos Filtrados del Sistema Convencional (Cuadro 24), con un $R^2 = 95.634\%$ y su CME=0.36411.

Cuadro 24. Estadísticos de las mejores configuraciones de red para los datos filtrados. Sistema Convencional.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	90.318	90.658	91.708	R2
	0.65175	0.62798	0.55146	CME
3	5,5	10,5	15,5	*
	91.099	92.274	93.847	R2
	0.61695	0.56416	0.44523	CME
	5,10	10,10	15,10	*
	91.451	93.476	94.227	R2
	0.59302	0.47274	0.3951	CME
	5,15	10,15	15,15	*
	91.575	93.737	94.549	R2
	0.5991	0.45052	0.40904	CME
	10,10,10	10,15,10	15,10,15	*
	93.41	94.863	94.986	R2
	0.48435	0.39518	0.40116	CME
4	15,10,10	15,15,10	15,15,15	*
	94.583	95.089	95.634	R2
	0.41529	0.41256	0.36411	CME

(*) Número de neuronas en las capas ocultas.

Al comparar el comportamiento de las mejores Redes Neuronales obtenidas para el Sistema Convencional (Cuadro 25) se encuentra que, mientras la mejor ANN para datos sin filtrar tiene un arquitectura más sencilla, su grado de ajuste es 7.252% menor que la red generada con datos filtrados y presenta un cuadrado medio del error 233%

mayor que la red de datos filtrados. Por lo tanto, la mejor ANN para este Sistema es la generada con datos filtrados y con estructura de 4 capas y 15-15-15 neuronas en las capas ocultas.

Cuadro 25. Comparación entre las mejores Redes Neuronales del Sistema Convencional.

Origen de los datos	Estructura de la red		Estadísticos	
	Número de capas	Neuronas en capas ocultas	R ²	CME
Convencional sin filtrar	3	10-10	88.382	0.85130
Convencional Filtrados	4	15-15-15	95.634	0.36411

Para el Sistema Des-Fog, la ANN de 3 capas y 15-15 neuronas en las capas ocultas (Cuadro 26) aplicada a los datos sin filtrar, presenta el mejor desempeño, tanto en ajuste como en el valor del cuadrado medio del error, **86.264%** y 0.90511, respectivamente.

Cuadro 26. Estadísticos de las mejores configuraciones de red para los datos no filtrados. Sistema Des-Fog.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	83.708	83.951	84.807	R2
	1.102	1.1102	1.0571	CME
3	5,5	10,5	15,5	*
	84.054	84.323	84.992	R2
	1.0043	1.0776	1.0309	CME
	5,10	10,10	15,10	*
	84.901	85.161	85.286	R2
	0.98256	0.99157	0.95004	CME
	5,15	10,15	15,15	*
	85.222	85.765	86.264	R2
	0.99017	0.91807	0.90511	CME

(*) Número de neuronas en las capas ocultas.

Cuando se procesan los datos filtrados del Sistema Des-Fog, se considera como la mejor alternativa la ANN de 4 capas y 15-15-15 neuronas en las capas ocultas (Cuadro 27), pues presenta el mejor coeficiente de correlación, **R²=95.09%**, a pesar de que su

desempeño (CME=0.33466) es mayor en 0.00929 unidades que la Red de 4 capas y 10-10-10 neuronas en las capas ocultas.

Cuadro 27. Estadísticos de las mejores configuraciones de red para los datos filtrados. Sistema Des-Fog.

Capas	Desempeño según arquitectura de la red			
2	5	10	15	*
	91.064	91.576	92.214	R2
	0.50233	0.51134	0.44958	CME

3	5,5	10,5	15,5	*
	91.801	92.486	93.207	R2
	0.49988	0.43889	0.43949	CME
	5,10	10,10	15,10	*
	91.881	93.067	93.64	R2
	0.4786	0.44046	0.39378	CME
	5,15	10,15	15,15	*
	92.782	93.775	94.047	R2
	0.41636	0.38944	0.3851	CME

4	10,10,10	10,15,10	15,10,15	*
	94.561	94.936	93.876	R2
	0.32537	0.34083	0.39962	CME
	15,10,10	15,15,10	15,15,15	*
	94.471	94.646	95.09	R2
	0.34471	0.34494	0.33466	CME

(*) Número de neuronas en las capas ocultas.

Del Cuadro 28 puede verse cómo la ANN generada con datos filtrados tiene el mejor comportamiento, pues el coeficiente de correlación es 8.826% mayor a la mejor Red para datos no filtrados, mientras que su cuadrado medio del error (que durante las iteraciones se toma como método para evaluar el desempeño de cada Red) es 270% menor.

Cuadro 28. Comparación entre las mejores Redes Neuronales del Sistema Des-Fog.

Origen de los datos	Estructura de la red		Estadísticos	
	Número de capas	Neuronas en capas ocultas	R ²	CME
Des-Fog sin filtrar	3	15-15	86.264	0.90511
Des-Fog Filtrados	4	15-15-15	95.09	0.33466

Para los datos sin filtrar, tanto para el sistema Convencional como para el Desfog, , sólo se probaron redes de 3 capas, pues el comportamiento de éstas, no generó en ninguna iteración ajustes iguales o superiores al 90%.

4.2.4.1 Simulación con la mejor Red Neuronal del Sistema Convencional.

Una vez elegida la mejor Red Neuronal para el Sistema Convencional, se emplea para realizar la Simulación de todos los datos, tanto de las variables climáticas al interior del invernadero, como del equipo de Fitomonitorio, y se recalcula el grado de ajuste, así como el Cuadrado Medio del Error. Esto se hace porque el R^2 y CME reportados por el Neural Network Toolbox Graphical User Interface de MATLAB es el promedio de esos estadísticos (Figura 4.54, cuarto cuadrante, derecha inferior), para tres subconjuntos que provienen del 100% de datos: Entrenamiento (50%), Validación (25%) y Prueba (25%). Los datos de cada subconjunto se eligen de forma aleatoria a lo largo de la matriz de información.

En la Figura 4.55 se muestran seis días de la Simulación de la Red Neuronal para todo el conjunto de datos tomados durante el periodo de experimentación; se observa el comportamiento que tiene la fotosíntesis cuando se le alimenta con las siguientes variables de entrada: 1) Radiación PAR (Wm^{-2}), 2) Temperatura ($^{\circ}\text{C}$), 3) Humedad Relativa (%), 4) Déficit de Presión de Vapor (kPa) y, 5) disponibilidad de CO_2 al interior del invernadero (ppm). Se aprecia lo bien que trabaja la red, pues en ausencia de radiación predice nula actividad fotosintética, mientras que durante horas de radiación sigue la tendencia de la curva de fotosíntesis medida con un buen grado de ajuste, con lo que queda clara la alta capacidad de las redes neuronales artificiales para modelar sistemas altamente no lineales, en este caso la fotosíntesis.




Figura 4.54) Ajuste de la mejor Red Neuronal del Sistema Convencional de acuerdo con el Neural Network Toolbox Graphical User Interface de MATLAB.




Figura 4.55) Simulación de la mejor ANN para los datos del Sistema Convencional.

Para evaluar el comportamiento general de la Red Neuronal elegida (tomando en cuenta los 22402 puntos de mediciones), se emplea el Curve Fitting Tool de MatLab.

Los estadísticos de la regresión lineal aplicada (Figura 4.56) entre datos medidos y simulados son los siguientes:

Modelo polinomial de primer orden:

$$f(x) = p1 * x + p2$$

Coefficientes del modelo con los intervalos de confianza al 95%:

$$p1 = 0.9229 \text{ (0.9192,0.9266)}$$

$$p2 = 0.08312 \text{ (0.07517,0.09107)}$$

Suma de los cuadrados del error (SCE)= 6325

Coefficiente de correlación: $R^2 = 0.9141$

Cuadrado medio del error: CME= 0.2823

Raíz del CME: RCME= 0.5314




Figura 4.56) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones del Sistema Convencional.

Con la regresión lineal se logra 91.41% de ajuste entre los valores de Fotosíntesis simulada con la Red Neuronal y la Fotosíntesis medida. Así mismo, se puede observar

claramente como la mayor parte de la nube de puntos cae dentro de los límites de confianza al 95% para la ecuación de ajuste, lo cual se debe a que el valor de la raíz del Cuadrado Medio del Error (RCME) es bajo, 0.5314.

Al realizar las pruebas estadísticas a la Red Neuronal de 4 capas y 15-15-15 neuronas en las capas ocultas, para los datos de entrada filtrados por el Método Savitzky Golay, se observa el excelente desempeño de ésta para todo el conjunto de datos. El valor del ajuste en la regresión mostrada en la Figura 4.56, es sólo 4.224% menor al reportado por el Neural Network Toolbox Graphical User Interface de MATLAB. El Cuadrado Medio del Error entre la tasa de fotosíntesis simulada por la ANN para todo el conjunto de mediciones resultó ser menor (0.2823) que el valor generado como promedio de los subconjuntos de datos para entrenar la red (0.36411). Esto último puede deberse al error tan pequeño que se genera cuando la red ajusta la curva de fotosíntesis durante las horas sin radiación, pues como se vio en la Figura 4.55, la predicción de la ANN es cero para esa condición climática tal como es el comportamiento del proceso fisiológico.

4.2.4.2 Simulación con la mejor Red Neuronal del Sistema Des-Fog.

De forma similar, se realiza la simulación con la mejor Red Neuronal para todos los datos del Sistema Des-Fog y se recalcula el grado de ajuste, así como el Cuadrado Medio del Error, por las razones ya explicadas en el punto anterior. Los coeficientes, R^2 y CME reportados por el Neural Network Toolbox Graphical User Interface de MATLAB para la mejor arquitectura de red encontrada, se muestran en la Figura 4.57. El coeficiente de correlación general para los subconjuntos Entrenamiento, Validación y Prueba para la red, se ubica en el cuarto cuadrante, derecha inferior de la misma Figura.




Figura 4.57) Ajuste de la mejor Red Neuronal del Sistema Des-Fog, de acuerdo con el Neural Network Toolbox Graphical User Interface de MATLAB.

En la Figura 4.58 se muestran seis días de la Simulación de la Red Neuronal para todo el conjunto de datos tomados durante el periodo de experimentación; se observa el comportamiento que tiene la fotosíntesis cuando se le alimenta con las siguientes variables de entrada: 1) Radiación PAR (Wm^{-2}), 2) Temperatura ($^{\circ}\text{C}$), 3) Humedad Relativa (%), 4) Déficit de Presión de Vapor (kPa) y, 5) disponibilidad de CO_2 al interior del invernadero (ppm). En la Figura puede apreciarse que, al igual que la ANN para datos del Sistema convencional, durante las horas de radiación nula, el valor que predice la Red está sobre el valor de cero desde que el proceso de fotosíntesis culmina.




Figura 4.58) Simulación de la mejor ANN para los datos del Sistema Des-Fog.

Para evaluar el comportamiento general de la Red Neuronal elegida (a lo largo de los 22402 puntos de mediciones), se emplea el Curve Fitting Tool de MatLab. Los estadísticos de la regresión lineal aplicada (Figura 4.59) entre datos medidos y simulados son los siguientes:

Modelo polinomial de primer orden:

$$f(x) = p1 * x + p2$$

Coefficientes del modelo con los intervalos de confianza al 95%:

$$p1 = 0.9068 \text{ (0.9029,0.9108)}$$

$$p2 = 0.09684 \text{ (0.08895,0.1047))}$$

Suma de los cuadrados del error (SCE)= 6191

Coefficiente de correlación: $R^2 = 0.9007$

Cuadrado medio del error: CME= 0.2763

Raíz del CME: RCME= 0.5257




Figura 4.59) Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones del Sistema Des-Fog.

Con la regresión lineal se logra 90.07% de ajuste entre los valores de Fotosíntesis simulada con la Red Neuronal y la Fotosíntesis medida. El valor de la raíz del Cuadrado Medio del Error (RCME) es bajo, 0.5257. Al realizar las pruebas estadísticas a la Red Neuronal de 4 capas y 15-15-15 neuronas en las capas ocultas, para los datos de entrada filtrados por el Método Savitzky Golay, se observa el excelente desempeño de ésta para todo el conjunto de datos. El valor del ajuste en la regresión mostrada en la Figura 4.59, es sólo 5.02% menor al reportado por el Neural Network Toolbox Graphical User Interface de MATLAB. El Cuadrado Medio del Error entre la tasa de fotosíntesis simulada por la ANN para todo el conjunto de mediciones resultó ser menor (0.2763) que el valor generado como promedio de los subconjuntos de datos para entrenar la red (0.33466). El comportamiento del CME resulta ser el mismo al obtenido cuando se simuló la Red del Sistema Convencional, por lo tanto, se asume la misma explicación.

De acuerdo con los valores descritos arriba, al igual que con el Sistema Convencional, se encontró una Red Neuronal válida, que no sobreestima el ajuste para todo el conjunto de datos, además de conservar las tendencias estadísticas resultantes después de ser entrenada.

A diferencia de los resultados de la sección 4.1.4, las Redes Neuronales obtenidas (para los datos de los invernaderos experimentales de la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín) presentan menor ajuste tomando en cuenta el coeficiente de correlación 0.9141 y 0.9007 para el sistema Convencional y Des-Fog, respectivamente, comparado con el $R^2 = 0.9756$ de los datos de Querétaro, México; sin embargo, considerando el cuadrado medio del error, las ANN encontradas en esta sección presentan mejor desempeño, 0.2823 y 0.2763 para cada sistema, contra 0.8532 del sistema comparado. Lo anterior se debe a la cantidad de información con que se generó y se verificaron las redes; para Querétaro, la matriz de información fue de 4820 x 6, mientras que para Berlín fue de 22402 x 6.

Las ANN encontradas en esta investigación difieren principalmente a las reportadas por Salazar *et al.* (2010), en que éstas últimas emplean como variable de entrada el vector de valores de fotosíntesis proveniente del Sensor PTM-48 para calcular la fotosíntesis futura 5 y 10 minutos adelante. Además, la matriz de información empleada en el trabajo mencionado, proviene sólo de un mes de mediciones (Junio de 2007), en contraste con tres meses de mediciones reportados en esta sección (Agosto a Noviembre, 2009). Esto significa que las redes generadas en este capítulo tienen un entrenamiento más robusto, puesto que las condiciones climáticas (principalmente

radiación PAR) cambian muy drásticamente a lo largo de los 99 días de mediciones, como se explicó en la sección 4.2.1.1.

4.2.5 Ruta de la Fotosíntesis en función de la relación entre dos variables climáticas.

En esta sección de resultados se muestra el comportamiento de la variable Fotosíntesis en función de dos condiciones climáticas simultáneas. Se combinaron los datos filtrados por el Método Savitzky Golay, tanto del Sistema Convencional como del Des-Fog, para crear la matriz que contiene las variables que determinan el microclima de los invernaderos. El vector de valores para fotosíntesis proviene de la unión de las salidas de las simulaciones de las mejores Redes Neuronales de ambos sistemas. La matriz de datos, resultante tiene más información de tendencias y patrones que si se les tratara de manera individual. Las ANN empleadas para generar los valores de fotosíntesis, se explican de manera detallada en el capítulo 4.2.4.

4.2.5.1 Fotosíntesis vs Temperatura - Concentración de CO₂

Como se observa en la Figura 4.60, la tasa de fotosíntesis comienza a tener valores por arriba de $5 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$ a partir de los 25°C. Las tasas máximas de fotosíntesis, de acuerdo a la función de ajuste, se logran con temperaturas alrededor de 30°C. De la Figura (recuadro inferior) pueden verse también tres líneas paralelas de temperaturas, 19°C, 23°C y 26°C sobre las que se mueve la mayor parte de puntos de fotosíntesis. Usando estas líneas de referencia, puede notarse que a medida que la temperatura aumenta, la tasa de fotosíntesis comienza a incrementarse, a pesar de mantenerse constante la concentración de CO₂ al interior de los invernaderos. Lo anterior significa que ligeras variaciones en la variable temperatura tienen mayor

impacto sobre la tasas de fotosíntesis que la práctica de enriquecer con gas CO_2 el ambiente invernadero. Puede verse por ejemplo que, cuando la concentración del dióxido de carbono se encuentra en las 800 ppm y la temperatura es 18°C , la tasa de fotosíntesis es menor a $2 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$. Por el contrario, cuando la temperatura esta en los 25°C , con el mismo nivel de CO_2 , la tasa llega a los $5 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$.




Figura 4.60) Fotosíntesis en función de las variables Temperatura y Concentración de CO_2 . Arriba, superficie de la función polinomial de orden 3-2 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

A pesar de que el modelo de regresión no tiene un coeficiente de correlación alto ($R^2=0.54$), se le toma como un buen indicador del comportamiento de las variables Temperatura, CO_2 y Fotosíntesis, pues como se ve, la superficie de la función describe muy bien la trayectoria de la nube de puntos. El modelo, sus parámetros y las estadísticas de ajuste se muestran enseguida.

```
Linear model Poly32:
fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2 + p30*x^3
                + p21*x^2*y + p12*x*y^2
Coefficients (with 95% confidence bounds):
p00 =      85.53   (80.65, 90.41)
p10 =     -10.75   (-11.28, -10.22)
p01 =     -0.06618 (-0.07405, -0.0583)
p20 =      0.4264   (0.4079, 0.4448)
p11 =      0.005713 (0.005104, 0.006322)
p02 =    1.556e-005 (1.127e-005, 1.986e-005)
p30 =    -0.005234 (-0.005436, -0.005032)
p21 =    -0.000115 (-0.000127, -0.0001029)
p12 =   -7.295e-007 (-9.399e-007, -5.191e-007)

gof =

      sse: 6.2247e+004
    rsquare: 0.5424
       dfe: 44795
adjrsquare: 0.5424
       rmse: 1.1788
```

4.2.5.2 Fotosíntesis vs Radiación –Déficit de Presión de Vapor

La Radiación Fotosintéticamente Activa es muy importante en el incremento de la Fotosíntesis, pues como se observa en la Figura 4.61, con niveles entre $160\text{-}180\text{ Wm}^{-2}$ se alcanza un máximo en la función de ajuste. Por el contrario, niveles inferiores a 40 Wm^{-2} generan los peores valores de fotosíntesis, por debajo de $5\text{ }\mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$, independientemente del valor que tome el VPD.

Por su parte, cuando el Déficit de Presión de Vapor está por arriba de 2.5 kPa y por debajo de 1.5 kPa , la trayectoria de la fotosíntesis no se dirige hacia el máximo de la función, por el contrario, comienza a decrecer aún para los mismos niveles de radiación

PAR. Por lo tanto, es importante mantener el VPD lo más cercano a 2 kPa cuando se presentan niveles de radiación superiores a 40 Wm^{-2} , para asegurar la apertura estomática y con ello, el ingreso del CO_2 al interior de las hojas. Puede verse de la Figura que una buena parte de la nube de puntos, localizada en $\text{PAR} > 40 \text{ Wm}^{-2}$, estuvo mal manejada, pues los niveles del VPD se mantuvieron demasiado bajos.




Figura 4.61) Fotosíntesis en función de las variables Radiación y VPD. Arriba, superficie de la función polinomial de orden 4-4 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida.

```
Linear model Poly44:
fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2 + p30*x^3
               + p21*x^2*y + p12*x*y^2 + p03*y^3 + p40*x^4 + p31*x^3*y
               + p22*x^2*y^2 + p13*x*y^3 + p04*y^4
Coefficients (with 95% confidence bounds):
p00 = 0.05957 (0.04022, 0.07892)
p10 = 0.2012 (0.1992, 0.2031)
p01 = -0.5126 (-0.5952, -0.43)
p20 = -0.003861 (-0.003932, -0.00379)
p11 = 0.04127 (0.03822, 0.04433)
p02 = 0.4842 (0.3649, 0.6035)
p30 = 2.619e-005 (2.53e-005, 2.709e-005)
p21 = 0.000161 (0.000124, 0.0001981)
p12 = -0.01727 (-0.01901, -0.01553)
p03 = -0.1548 (-0.2121, -0.09754)
p40 = -5.823e-008 (-6.192e-008, -5.454e-008)
p31 = -9.896e-007 (-1.233e-006, -7.46e-007)
p22 = 1.361e-005 (1.832e-006, 2.539e-005)
p13 = 0.00143 (0.001044, 0.001816)
p04 = 0.01707 (0.008667, 0.02548)

gof =

      sse: 1.9646e+004
    rsquare: 0.8556
      dfe: 44789
adjrsquare: 0.8555
      rmse: 0.6623
```

4.2.5.3 Fotosíntesis vs Temperatura – Humedad Relativa

Existe una línea a los 25°C (Figura 4.62) en que la función de ajuste tiene un límite de inflexión; con un incremento de la temperatura a partir de ese punto, la tasa de fotosíntesis se dirige hacia un máximo, mientras que si la temperatura desciende, la trayectoria de la nube de puntos de fotosíntesis toma la ruta hacia el mínimo de la función.

Niveles de Humedad Relativa superiores a 60% cuando la temperatura está por debajo de los 25°C aseguran que el proceso de fotosíntesis se reduzca hasta alcanzar valores inferiores a $2 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$; por el contrario, cuando la temperatura se

encuentra por encima del mismo valor, lo ideal es mantener la humedad relativa por arriba del 60%, ya que, como se ve en la Figura, si la temperatura es alta y la humedad relativa es muy baja (inferior al 40%), la tendencia de la fotosíntesis es dirigirse hacia un mínimo de la función.




Figura 4.62) Fotosíntesis en función de las variables Temperatura y Humedad Relativa. Arriba, superficie de la función polinomial de orden 3-2 para ajuste de los datos. Abajo, esquema para facilitar el entendimiento de las relaciones entre variables.

El modelo, sus parámetros y las estadísticas de ajuste, principalmente R^2 y RMSE, se muestran enseguida.

```
Linear model Poly32:
fitresult(x,y) = p00 + p10*x + p01*y + p20*x^2 + p11*x*y + p02*y^2 + p30*x^3
                + p21*x^2*y + p12*x*y^2
Coefficients (with 95% confidence bounds):
p00 =      31.07  (25.06, 37.07)
p10 =     -3.428  (-4.049, -2.807)
p01 =     -0.3014 (-0.3814, -0.2215)
p20 =      0.1439 (0.1223, 0.1655)
p11 =      0.008672 (0.003357, 0.01399)
p02 =      0.002388 (0.002043, 0.002733)
p30 =     -0.002004 (-0.002256, -0.001752)
p21 =    9.695e-005 (1.361e-005, 0.0001803)
p12 =   -8.939e-005 (-0.0001047, -7.405e-005)

gof =

      sse: 6.7537e+004
    rsquare: 0.5036
      dfe: 44795
adjrsquare: 0.5035
      rmse: 1.2279
```

En las estadísticas que describen a las funciones de las superficies generadas para los datos de Berlín, puede verse que el valor del coeficiente de regresión (R^2) es más pequeño en comparación con los valores obtenidos con los datos provenientes del invernadero experimental de la Universidad Autónoma de Querétaro. Lo anterior se debe principalmente al tiempo de muestreo (5min), que se reduce a la mitad con respecto de los datos de Querétaro (10min), así como a la cantidad de información procesada, que en este caso, es 4.6 veces mayor.

5. CONCLUSIONES

Dentro de los Modelos Matemáticos Dinámicos derivados de la Teoría de Identificación de Sistemas que fueron evaluados, los lineales y no lineales de Autoregresión con Variables Exógenas (ARX, nLARX, respectivamente) mostraron un comportamiento superior, con respecto de modelos como los Auto-regresivos con Promedio Móvil y Entradas Exógenas (ARMAX), Box-Jenkins (BJ) y Error de la salida (OE), teniendo en cuenta el grado de ajuste de las simulaciones contra mediciones de la tasa de fotosíntesis de hojas de tomate (*Lycopersicon esculentum*).

En el caso de los datos experimentales del invernadero de la Universidad Autónoma de Querétaro, el mejor modelo obtenido fue un ARX; éste se obtuvo al emplear 80% de datos para estimación y 20% de datos para validación. El orden del modelo es: $na=[7]$, $nb=[2\ 4\ 4\ 5\ 5]$, $nk=[2\ 1\ 2\ 4\ 5]$, con un grado de ajuste en la simulación de los datos de validación de 50.3%.

Es notoria la baja capacidad de este modelo lineal en el correcto seguimiento de la tendencia de la variable respuesta fotosíntesis. Sin embargo, empleando el mismo modelo en predicción 5 pasos hacia adelante, el grado de ajuste mejora considerablemente, hasta 89.61% para el mismo conjunto de datos de validación. La

razón radica en que, durante la predicción, la variable salida es tomada en cuenta para recalcular la nueva; no obstante, debido al alto costo de un sistema de fitomonitorio, como el empleado en esta investigación, no es posible usar en la práctica un modelo en el que, como variable de entrada, se requiera a la fotosíntesis $k-1$ pasos de tiempo en el pasado.

A diferencia de los resultados obtenidos para el sitio experimental de Querétaro, los mejores ajustes para los datos provenientes de los invernaderos con Sistema Convencional y Des- Fog de la Universidad Humboldt de Berlín, se obtuvieron con un modelo ARX no lineal; sin embargo, al comparar las simulaciones y mediciones de la tasa de fotosíntesis para cada sistema, éstas se encuentran por debajo de 30%; lo anterior se debe principalmente al tiempo de muestreo (5min), que se reduce a la mitad con respecto de los datos de Querétaro (10min), así como a la cantidad de información procesada, que en este caso, es 4.6 veces mayor. Por lo tanto, puede verse que los modelos de caja negra lineales (ARX) evaluados no son capaces de explicar la trayectoria de la fotosíntesis, a partir de cinco variables de entrada: 1) Radiación, 2) Temperatura, 3) Humedad Relativa, 4) Déficit de Presión de Vapor y, 5) Concentración de CO_2 .

El Modelo Mecanicista de Goudriaan presentó mejores índices estadísticos en la simulación de la fotosíntesis foliar de plantas de tomate. Para los datos de Querétaro, el coeficiente de regresión (R^2) asciende a 0.9452, mientras que el cuadrado medio del error (CME_1) es de 0.0035. En el caso de los sistemas Convencional y Des-Fog de los invernaderos experimentales de la Universidad Humboldt, los parámetros estadísticos de prueba fueron: $R^2 = 0.7513$, $\text{CME}_2 = 0.0039$, y $R^2 = 0.7941$, $\text{CME}_3 = 0.0032$,

respectivamente. Al obtener la raíz cuadrada del cuadrado medio del error (RCME) para $CME_1:CME_3$, se tiene que el margen de error (al comparar con la tasa máxima de fotosíntesis medida, A_{max} , de cada experimento) entre los valores resultantes de la simulación contra los valores reales, puede llegar a 6.7%, 12.68% y 13.74% para los modelos calibrados de Querétaro, Berlín Convencional y Berlín Des-Fog, respectivamente.

El grado de ajuste del modelo ya calibrado, para cada sitio experimental, es aceptable, más no ideal. Esto se debe a que el Modelo Mecanicista de Goudriaan, contenido en la Subrutina del Modelo SUCROS, que calcula la tasa de fotosíntesis foliar, lo hace en función de la elevación solar para un día Juliano dado. El modelo sólo toma la cantidad de radiación PAR disponible, así como parámetros que únicamente definen su impacto sobre el dosel (SCP, KDF, EFF, ATMTR) como única variable que influye en el comportamiento de la fotosíntesis foliar, dejando a un lado el resto de variables climáticas tales como temperatura, humedad relativa y concentración de CO_2 . Además, en el caso de la simulación de la fotosíntesis en los experimentos de Berlín, como se explicó en la sección 4.2.1.1, existen muchas condiciones desfavorables para el paso de la radiación al interior de los invernaderos y dado el tipo de modelo, los ajustes son mucho menores a los encontrados en el invernadero experimental de la Universidad Autónoma de Querétaro.

Al comparar los valores que resultaron de la calibración del parámetro Eficiencia del Uso de la Radiación (EFF) para los datos de los Invernaderos de Dahlem, Berlín, Alemania con el valor del mismo parámetro para los datos de Amazcala, Querétaro, México, se encontró que para el cultivo de tomate (*Lycopersicon esculentum*), la EFF

(que es una característica propia de cada especie vegetal) es de $0.0180^{+0.0004}_{-0.0} [mgCO_2J^{-1}]$.

Por otro lado, las mejores Redes Neuronales, que son modelos de caja negra no lineales, obtenidas para simular la tasa de fotosíntesis foliar de plantas de tomate tuvieron un arquitectura de 4 capas con 15-15-15 neuronas en las capas ocultas para el caso de los datos de Berlín, tanto del sistema Convencional como del Des-Fog; mientras que la estructura de la mejor ANN de Querétaro, tiene 10-15-10 neuronas en las capas ocultas. En el último caso, a medida que se incrementa el número de neuronas, el ajuste entre simulaciones y mediciones comienza a decrecer.

Las Redes Neuronales creadas a partir de los datos de los invernaderos experimentales de la División de Ingeniería en Biosistemas de la Universidad Humboldt de Berlín, presentan menor ajuste tomando en cuenta el coeficiente de correlación $R^2=0.9141$ y $R^2=0.9007$ para el sistema Convencional y Des-Fog, respectivamente, comparado con el $R^2=0.9756$ para los datos de Querétaro, México. Lo anterior se debe a la cantidad de información con que se generaron y verificaron las redes; para Querétaro, la matriz fue de 4820 x 6 datos, mientras que para Berlín fue de 22402 x 6.

Para poder tener una base de comparación entre los estadísticos de los mejores Modelos evaluados, en este caso el Modelo Mecanicista de Goudriaan y las Redes Neuronales, también se calculan para estas últimas, los márgenes de error (a partir del RCME y de la *Amax* para cada sistema) entre los valores resultantes de la simulación contra los valores reales: 4.7%, 5.6% y 4.6%, sistema Convencional, Des-Fog y para la ANN de Querétaro, respectivamente. Este procedimiento se lleva a cabo puesto que el

modelo de Goudriaan reporta los valores de fotosíntesis en unidades de $mgCO_2m^{-2}s^{-1}$, mientras que en las Redes Neuronales se trabajaron como $\mu molCO_2m^{-2}s^{-1}$.

Al comparar los coeficientes de correlación y los valores del margen de error de las simulaciones contra mediciones entre los modelos de Goudriaan y de Redes Neuronales, para cada sistema de esta investigación, puede concluirse que los mejores modelos, para simular la tasa de fotosíntesis foliar de plantas de tomate, son las Redes Neuronales Artificiales, puesto que describen con un grado de ajuste muy alto la relación entre ésta y las variables climáticas: radiación, temperatura, humedad relativa, déficit de presión de vapor y concentración de CO_2 .

Las ANN encontradas en esta investigación difieren principalmente a las reportadas por Salazar *et al.* (2010), en que éstas últimas emplean como variable de entrada el vector de valores de fotosíntesis proveniente del Sensor PTM-48 para calcular la fotosíntesis futura 5 y 10 minutos adelante, de ahí que el ajuste entre mediciones y predicciones sea superior en 6% a los resultados presentados en este trabajo. Además, la matriz de información empleada en el trabajo mencionado, proviene sólo de un mes de mediciones (Junio de 2007), en contraste con tres meses de mediciones reportados en esta sección (Agosto a Noviembre, 2009). Esto significa que las redes generadas en este capítulo tienen un entrenamiento más robusto, puesto que las condiciones climáticas (principalmente radiación PAR) cambian muy drásticamente a lo largo de los 99 días de mediciones, como se explicó en la sección 4.2.1.1.

Finalmente, a partir de las superficies generadas con los datos de las simulaciones de las mejores Redes Neuronales Artificiales para cada sitio experimental, es posible

tener una mejor comprensión de la interacción entre las condiciones climáticas dentro de los invernaderos y la tasa de fotosíntesis foliar del cultivo del tomate.

Así mismo, a partir de las funciones con que se generaron las superficies, se pueden ver las rutas que deben seguir las variables climáticas, de tal forma de que el control ambiental de los invernaderos siempre esté enfocado hacia el máximo de la función es decir, a la obtención de la tasa máxima de fotosíntesis dependiendo de las condiciones existentes.

BIBLIOGRAFIA

- Allen, R. G., L. S. Pereira, D. Raes, M. Smith. 2006. Boletín 56 FAO: Evapotranspiración del cultivo: Guías para la determinación de los requerimientos de agua de los cultivos.
- Amir, R., and M. A. Teitel. 2005. CO₂ enrichment in fan-ventilated greenhouse under different ventilation modes. *Acta Hort.* 691: 619-624.
- Anten, N. P. R. 1997. Modelling canopy photosynthesis using parameters determined from simple non-destructive measurements. *Ecological Research.* 12: 77-88.
- Azcon-Bieto, J., and M. Talon. 1993. *Fisiología y Bioquímica Vegetal*. McGraw-Hill Interamericana de España.
- Bailey, B. J., Z. S. Chalabi, D. P. Aikman, and K. E. Cockshull. 1997. Improved strategies for controlling CO₂ enrichment in tomato greenhouses. *Acta Hort.* 443: 155-162.
- Boote, K. J., and J. M. S. Scholberg. 2006. Developing parameterizing and testing of dynamic crop growth models for horticultural crops. *Acta Hort.* 718: 23-34.
- Cengel, Y. A., and M. A. Boles. 2005. *Thermodynamics: An Engineering Approach*. 5th Edition. McGraw-Hill Science.
- Chen, J. M., J. Liu, J. Cihlar, and M. L. Goulden. 1999. Daily canopy photosynthesis model through temporal and spatial scaling for remote sensing applications. *Ecological Modelling.* 124: 99-119.
- Chengwei, M., and H. Fen. 2010. Modeling greenhouse air humidity by means of artificial neural network and principal component analysis. *Computers and Electronics in Agriculture* 71S: S19-S23.
- Demuth, H., M. Beale, and M. Hagan. 2009. *Neural Network Toolbox™ 6. User's Guide*. The MathWorks, Inc. Natick, MA.

- de Pury, D. G. G., and G. D. Farquhar. 1997. Simple scaling of photosynthesis from leaves to canopies without the errors of big-leaf models. *Plant, Cell and Environment*. 20: 537-557.
- Ethier, G. J., and N. J. Livingston. 2004. On the need to incorporate sensitivity to CO₂ transfer conductance into the Farquhar-von Caemmerer-Berry leaf photosynthesis model. *Plant, Cell and Environment*. 27: 137-153.
- Evans, J. R., and F. Loreto. 2000. Acquisition and diffusion of CO₂ in higher plant leaves. *Photosynthesis, Physiology and Metabolism*. Kluwer Academic Publishers, The Netherlands. pp. 321-351.
- Farquhar, G. D., S. von Caemmerer, and J. A. Berry. 1980. A biochemical model of photosynthetic CO₂ assimilation in leaves of C3 species. *Planta*. 149: 78-90.
- Ferreira, P. M., E. A. Faria, and A. E. Ruano. 2002. Neural network models in greenhouse air temperature prediction. *Neurocomputing*. 43: 51-75.
- Frausto, H. U., and J. G. Pieters. 2004. Modelling greenhouse temperature using system identification by means of neural networks. *Neurocomputing* 56: 423-428.
- Gary, C. 199. Modelling greenhouse crops: state of the art and perspectives. *Acta Hort*. 495: 317-322.
- Gijzen, H., and J. A. ten Cate. 1988. Prediction of the response of greenhouse crop photosynthesis to environmental factors by integration of physical and biochemical models. *Acta Hort*. 229: 251-258.
- Gijzen, H., J. G. Vegter, and E. M. Nederhoff. 1990. Simulation of greenhouse crop photosynthesis: validation with cucumber, sweet pepper and tomato. *Acta Hort*. 268: 71-80.
- Goudriaan, J., and H. H. van Laar. 1994. *Modelling Potential Crop Growth Processes*. Kluwer Academic Publishers. 238 p.
- Hand, D. W. 1984. Crop response to winter and summer CO₂ enrichment. *Acta Hort*. 162: 45-60.

- Hagan, M. T., H. B. Demuth, and M. Beale. 1996. Neural network design. China Machine Press and CITIC Publishing House.
- Lambers, H., F. Stuart, and L. Thijs. 2008. Plant Physiological Ecology. Second Edition. Springer Editorial. 623 p.
- Heuvelink, E., M. Bakker, L. F. M. Marcelis and M. Raaphorst. 2008. Climate and yield in a closed greenhouse. Acta Hort. 801: 1083-1092.
- Körner, O. 2004. Evaluation of crop photosynthesis models for dynamic climate control. Acta Hort. 654: 295-302.
- Lieth, H., and S-H. Kim. 2003. A coupled model of photosynthesis, stomatal conductance and transpiration for a rose leaf (*Rosa hybrida* L.). Annals of Botany. 91: 771-781.
- Linker, R., and I. Seginer. 2004. Greenhouse temperature modeling: a comparison between sigmoid neural networks and hybrid models. Mathematics and Computers in Simulation 65: 19-29.
- Linker, R., P. O. Gutman, and I. Seginer. 2002. Observer-based robust failure detection and isolation in greenhouses. Control Engineering Practice 10: 519-531.
- Ljung, L. 2007. System Identification Toolbox 7. User's Guide. The MathWorks, Inc. Natick, MA.
- Ljung, L. 2008. Perspectives on system identification. 17th IFAC World Congress in Seoul, Korea.
- López-Cruz, I. L., A. Rojano-Aguilar, W. Ojeda-Bustamante, y R. Salazar-Moreno. 2007. Modelos ARX para predecir la temperatura del aire de un invernadero: una metodología. Agrociencia. 41: 181-192.
- López-Cruz, I. L., L. Hernández-Larragoiti. 2010. Modelos Neurodifusos para temperatura y humedad del aire en invernaderos tipo cenital y capilla en el centro de México. Agrociencia. 44: 791-805.

- Lootens, P., and P. Vandecasteele. 1998. Whole-plant net photosynthesis, an indication of actual growth, a tool for greenhouse climate control: a case study with *Ficus benjamina* 'Natasja'. Acta Hort. 421: 265-270.
- Marcelis, L. F. M., A. Elings, P. H. B. de Visser, and E. Heuvelink. 2009. Simulating growth and development of tomato crop. Acta Hort. 821: 101-110.
- Massacci, A., F. Pietrini, M. Centritto, and F. Loreto. 2000. Microclimate effects on transpiration and photosynthesis of cherry saplings growing under a shading net. Acta Hort. 537: 287-291.
- Millan, J. R., R. G. Guevara, R. J. Romero, R. A. Osornio, and I. Torres. 2009. Advantages and disadvantages on photosynthesis measurement techniques: A review. African Journal of Biotechnology. 25: 7340-7349.
- Monteith, J. L., and M. H. Unsworth. 1990. Principles of Environmental Physics. Second edition. Edward Arnold, a Division of Hodder and Stoughton. London.
- Nederhoff, E. M., and J. G. Vegter. 1994. Canopy photosynthesis of tomato, cucumber and sweet pepper in greenhouses: measurements compared to models. Annals of Botany. 73: 421-427.
- Pachepsky, L. B., and B. Acock. 1996a. An adequate model of photosynthesis – II. Dependence of parameters on environmental factors. Agricultural Systems. 50: 227-238.
- Pachepsky, L. B., J. D. Haskett, and B. Acock. 1996b. An adequate model of photosynthesis – I. Parameterization, validation and comparison of models. Agricultural Systems. 50: 209-225.
- Peart, R. M., and R. Bruce. 1998. Agricultural systems modeling and simulation. Marcel Dekker, Inc. The University of Florida, Gainesville, Florida.

- Roh, M. Y., Y. I. Nam, M. W. Cho, I. H. Yu, G. L. Choi, and T. Y. Kim. 2007. Environmental control in greenhouse based on phytomonitoring - leaf temperature as a factor controlling greenhouse environments. *Acta Hort.* 761: 71-76.
- Rojano, A., R. Salazar, U. Schmidt, and C. Huber. 2008. Spatial distribution of temperature, relative humidity and CO₂ in a venlo greenhouse. *Acta Hort.* 797: 199-202.
- Salazar, R., I. López, and A. Rojano. 2008. A neural network model to control greenhouse environment. Sixth Mexican International Conference on Artificial Intelligence, Special Session. p. 311-318.
- Salazar, R., U. Schmidt, C. Huber, A. Rojano, and I. López. 2010. Neural networks models for temperature and CO₂ control. *International Journal of Agricultural Research.* p. 1-10.
- Savitzky, A., and M. J. E. Golay. 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry.* 36: 1627-1639.
- Sciortino, M., D. Wulfsohn, A. Andreassen, G. Gianquinto, and J.M. Aaslyng. 2008. Validation of canopy photosynthesis models for climate control in greenhouses. *Acta Hort.* 801: 1309-1315.
- Schmidt, U. 2002. Modelling of stomatal conductance as a variable for environmental control in greenhouses. *Acta Hort.* 593: 227-234.
- Schmidt, U. 2004. Decision support for greenhouse climate control using a computerised Mollier diagram. *Acta Hort.* 654: 187-193.
- Schmidt, U. 2005. Microclimate control in greenhouses based on phytomonitoring data and Mollier phase diagram. *Acta Hort.* 691: 125-132.
- Schmidt, U., C. Huber, and T. Rocks. 2008. Evaluation of combined application of fog system and CO₂ enrichment in greenhouses by using phytomonitoring data. *Acta Hort.* 801: 1301-1307.

- Stanghellini, C. 1988. Microclimate and greenhouse crops. *Acta Hort.* 229: 405-410.
- Tantau, H. J. 1992. Estimation of the relative opening of the leaf stomata using energy balances. *Acta Hort.* 304:167-172.
- Tantau, H. J., U. N. Mutwiwa, and V. M. Salokhe. 2006. Response of tomato plants to natural ventilation and evaporative cooling methods. *Acta Hort.* 719: 447-454.
- Tantau, H. J., S. L. Patil, and V. M. Salokhe. 2008. Modelling of tropical greenhouse temperature by auto regressive and neural network models. *Biosystems Engineering.* 99: 423-431.
- Ton, Y., and M. Kopyt. 2003a. Phytomonitoring: a bridge from sensors to information technology for greenhouse control. *Acta Hort.* 614: 639-644.
- Ton, Y. and M. Kopyt. 2003b. Phytomonitoring in irrigation scheduling of horticulture crops. *Proceedings of the 4-th International Symposium on Irrigation of Horticultural Crops.*
- Ton, Y., N. Nilov, and M. Kopyt, 2001. Phytomonitoring: the new information technology for improving crop production. *Acta Hort.* 562: 257-262.
- van Henten, E. J. 2006. Greenhouse mechanization: state of the art and future perspective. *Acta Hort.* 710: 55-69.
- van Ooteghem, R. 2007. Optimal Control Design for a Solar Greenhouse. Ph. D. Thesis Wageningen University. The Netherlands.
- van Tuijl, B., E. van Os, and E. van Henten. 2008. Wireless sensor networks: state of the art and future perspective. *Acta Hort.* 801: 547-554.
- Wilkinson, R. E. 2000. *Plant-Environment Interactions*, Second edition, Marcel Dekker, Inc. The University of Georgia, Griffin, Georgia. United States of America, 466 p.

APÉNDICE A. NOTACIÓN

Nombre	Descripción	Unidades
AOB	Variable intermedia	-
AMAX	Tasa máxima de asimilación de las hojas a saturación de luz	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Atmtr	Coeficiente de transmisión atmosférica	-
AvRad	Radiación extraterrestre diaria disponible	$\text{Jm}^{-2}\text{s}^{-1} = \text{Wm}^{-2}$
Clustf	Factor de agrupamiento	-
Cosld	Variable intermedia para calcular la elevación solar	-
Dayl	Longitud del día	hd^{-1}
DEC	Declinación solar	radianes
DIA	Día Juliano	-
Dsinb	Integral del seno de la elevación solar por día	sd^{-1}
EFF	Eficiencia del uso de la radiación	$\text{mgCO}_2\text{J}^{-1}$
Fgl	Tasa de asimilación de CO_2 a una profundidad en el follaje	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Fgros	Tasa de asimilación instantánea de CO_2 por el follaje	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Fgrs	Variable intermedia para calcular la asimilación de hojas iluminadas por el sol	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Fgrsh	Tasa de asimilación de CO_2 a una profundidad en el follaje para hojas sombreadas	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Fgrsun	Tasa de asimilación de CO_2 a una profundidad en el follaje para hojas iluminadas por el sol	$\text{mgCO}_2\text{m}^{-2}\cdot\text{s}^{-1}$
Frdf	Fracción de la radiación difusa de la radiación entrante	-
Fslla	Fracción del área de hojas iluminadas por el sol	-
Iabs	Radiación teórica absorbida por el dosel en cada punto de Gauss	Jm^2s^{-1}
Iabsl	Radiación teórica local absorbida por el dosel	Jm^2s^{-1}

Iabsun	Radiación teórica absorbida a una profundidad en el follaje para hojas iluminadas por el sol	Jm^2s^{-1}
Kbl	Coeficiente de extinción para el componente directo del flujo de PAR	$\text{m}^2_{\text{suelo}} * \text{m}^{-2}_{\text{hoja}}$
KDF	Coeficiente de extinción de la radiación	$\text{m}^2_{\text{suelo}} * \text{m}^{-2}_{\text{hoja}}$
Kdrt	Coeficiente de extinción para el flujo total de PAR	$\text{m}^2_{\text{suelo}} * \text{m}^{-2}_{\text{hoja}}$
LAI	Índice de área foliar	$\text{m}^2_{\text{hoja}} * \text{m}^{-2}_{\text{suelo}}$
Laic	Índice de área foliar por encima de la profundidad del follaje seleccionada	$\text{m}^2_{\text{hoja}} * \text{m}^{-2}_{\text{suelo}}$
Latt	Latitud del lugar de estudio	grados
PAR	Radiación fotosintéticamente activa	Wm^{-2}
ParAbs	Radiación teórica absorbida por el dosel	Jm^2s^{-1}
Pardf	Componente difuso de la radiación fotosintéticamente activa	Wm^{-2}
Pardr	Componente directo de la radiación fotosintéticamente activa	Wm^{-2}
RAD	Factor para convertir grados a radianes	$\frac{\text{radianes}}{1} * \text{grados}^{-1}$
Refh	Coeficiente de reflexión para radiación PAR difusa	-
Refs	Coeficiente de reflexión para radiación PAR directa	-
Sc	Constante solar corregida por la variación de la distancia entre el sol y la tierra	Jm^2s^{-1}
SCP	Coeficiente de dispersión de las hojas para PAR	-
Sinb	Seno de la elevación solar	-
Sinld	Variable intermedia para calcular la declinación solar	-
Sqv	Variable intermedia para calcular el coeficiente de reflexión	-
Visd	Flujo de absorción por unidad de área foliar para el componente directo del flujo directo	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$
Visdf	Flujo de absorción por unidad de área foliar para el componente difuso	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$
Vispp	Flujo de absorción de luz para hojas perpendiculares al rayo de luz	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$

Visshd	Flujo total de absorción de luz para hojas sombreadas	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$
Vissun	Flujo total de absorción de luz para hojas iluminadas por el sol en cada uno de los puntos de Gauss	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$
Vist	Flujo de absorción por unidad de área foliar para el flujo total directo	$\text{Jm}^{-2}_{\text{hoja}} * \text{s}^{-1}$
