DOI: 10.22059/ijbse.2018.241916.664987 مهندسی بیوسیستم ایران، دوره ۴۹، شماره ۴، زمستان ۱۳۹۷ (ص۵۷۶-۵۶۷)

Temperature Prediction of a Greenhouse Equipped with Evaporative Cooling System Using Regression Models and Artificial Neural Network (Case Study in Kerman City)

MOHAMMAD HOSEIN SHOJAEI[1], HAMID MORTEZAPOUR[2*], KAZEM JAFARI NAIMI[3], MOHAMMAD MEHDI MAHARLOOEI[4]

1. Student in Department of Biosystems Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.
2. Assistant Professor in Department of Biosystems Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.
3. Assistant Professor in Department of Biosystems Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.
4. Assistant Professor in Department of Biosystems Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran.

(Received: Sep. 25, 2017- Revised: June. 24, 2018- Accepted: July. 8, 2018)

ABSTRACT

Today's agriculture, greenhouse cultivation plays a key role in increasing the quantity and quality of products. Indoor conditions of the greenhouse depend on some external factors, which are usually not easily predictable. The purpose of this study was to estimate the air temperature inside the greenhouse in two modes of ventilation (non-ventilated conditions and evaporative cooling system) using artificial neural network and regression models. Some factors such as solar irradiance, ambient temperature, northern wall temperature and flow rate and temperature of the cooling air were employed as the inputs of the models. Verification of the models was conducted using statistical criteria of mean square error, correlation coefficient and mean absolute percentage error. In order to train the neural network from multilayer perceptron with the algorithm of post-error learning and using the Levenberg-marquart training algorithms, the Bayesian regression and the gradient conjugate scalar, and in the regression model of the progressive and forward method for determining regression equations were used. Comparison of the statistical criteria indicated that the artificial neural network method predicted the greenhouse temperature with a higher accuracy than the regression model.

Key words: Greenhouse Temperature; Evaporative Cooling; Artificial Neural Network; Modeling

* Corresponding Author: h.mortezapour@uk.ac.ir

پیش بینی دمای هوای داخل گلخانه مجهز به سامانه‌ی سرمایش تبخیری با استفاده از مدل رگرسیونی و شبکه‌های عصبی مصنوعی (مطالعه موردی در شهر کرمان)

محمد حسین شجاعی[۱]، حمید مرتضی پور[۲]*، کاظم جعفری نعیمی[۳]، محمد مهدی مهارلوئی[۴]

۱. دانشجوی کارشناسی ارشد بخش مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲. استادیار بخش مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۳. استادیار بخش مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

۴. استادیار بخش مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

(تاریخ دریافت: ۳/ ۷/ ۱۳۹۶- تاریخ بازنگری: ۳/ ۴/ ۱۳۹۷- تاریخ تصویب: ۱۷/ ۴/ ۱۳۹۷)

چکیده

در کشاورزی امروزی، نقش گلخانه به عنوان ابزاری برای افزایش کمیت و کیفیت محصول، دارای اهمیت فراوان می‌باشد. شرایط داخلی گلخانه به برخی عوامل بیرونی وابسته است که به‌طور معمول پیش‌بینی دقیق آن‌ها به سادگی امکان پذیر نیست. هدف از اجرای این تحقیق، تخمین دمای هوای داخل گلخانه در حالت‌های بدون تهویه و با استفاده از سامانه‌ی سرماش تبخیری با روش شبکه عصبی مصنوعی و مدل رگرسیونی است. از برخی عوامل مانند شدت تابش خورشید، دمای هوای محیط، دمای دیواره شمالی گلخانه، دبی و دمای هوای ورودی به گلخانه، به‌عنوان ورودی مدل رگرسیونی و شبکه عصبی استفاده گردید. برای آموزش شبکه عصبی از پرسپترون چندلایه با الگوریتم یادگیری پس‌انتشار خطا و از الگوریتم‌های آموزش لونبرگ مارکوارت، تنظیم به‌روش بیزی و اسکالت کانژوگیت گرادینت و در مدل رگرسیونی از روش پیشرو و پسرو برای تعیین معادلات رگرسیونی استفاده شد. ارزیابی مدل شبکه عصبی و رگرسیونی با شاخص‌های آماری میانگن مربعات خطا، ضریب تبیین و معیار متوسط قدر مطلق خطا تعیین گردید. مقایسه نتایج آماری حاکی از دقت بالاتر شبکه عصبی مصنوعی نسبت به مدل رگرسیونی است.

واژه‌های کلیدی: دمای گلخانه؛ سرمایش تبخیری؛ شبکه عصبی مصنوعی؛ مدل سازی

مقدمه

سالنامه آماری فائو بیان می‌کند که به علت افزایش سطح زمین-های زیر کشت، تولید محصولات کشاورزی در جهان، به بیش از سه برابر ۵۰ سال قبل افزایش یافته است. با توجه به نیاز روز افزون بشر به مواد غذایی و افزایش بی‌رویه‌ی جمعیت، استفاده بهینه از منابع در جهان امروز بیش از پیش مورد توجه محققان قرار گرفته است (Dodange, 2011). از آنجا که زمین‌های قابل کشت کشاورزی کم می‌باشد، استفاده بهینه و حداکثری از این زمین‌ها اهمیت فراوان دارد. کشت گلخانه‌ای امکان استفاده از زمین کشاورزی را در تمام فصل‌های سال ایجاد می‌نماید. استفاده از گلخانه برای تولید محصولات کشاورزی به دلیل ایجاد امکاناتی از قبیل کنترل عوامل تاثیر گذار محیطی مانند تغییرات دمایی، کشت محصول در هر منطقه آب و هوایی، کنترل آفات و بیماری‌ها، جلوگیری از پدیده‌های سرمازدگی و گرمازدگی، استفاده بهینه از آب و خاک، راندمان بالای تولید، دوام محصول پس از برداشت، کاربرد مناسب کود و سم و در نهایت تولید محصول در خارج از شرایط زمانی و قیمت بالاتر محصول برای فروش در خارج از فصل، جایگاه ویژه‌ای به این نوع از تولید داده و موجب گسترش روزافزون کشت گلخانه‌ای به‌عنوان یک روش متفاوت با بازده بالا در سال‌های اخیر شده است (Dodange, 2011). نتایج تحقیقی نشان داد که اگرچه گلخانه یک محیط بسته است ولی مستقل از محیط بیرون نمی‌باشد. در نتیجه، شرایط داخل گلخانه به طور پیوسته تحت تاثیر آب و هوای بیرون است. چون شرایط دمایی هوای بیرون، طول روز، شدت نور و رطوبت هوا در حال تغییرند، تجهیزاتی در گلخانه نصب می‌شود که دما و رطوبت گلخانه را کنترل نمایند (Omid & Shafaei, 2004).

امروزه مدل‌های شبکه عصبی مصنوعی (ANN)، در اکثر جنبه‌های علم مهندسی و کشاورزی مورد استفاده قرار می‌گیرند. این ابزار به دلیل قابلیت مدل سازی سامانه‌های خطی و غیر خطی و همچنین عدم نیاز به هیچ‌گونه پیش شرطی، از علاقه-

* نویسنده مسئول: h.mortezapour@uk.ac.ir

مندان خاصی برخوردار است (Marcos *et al.*, Haykin, 1994 ;1992). استفاده از شبکه‌های عصبی مصنوعی در گلخانه می‌تواند به کشاورز اجازه برقراری ارتباطی قوی بین عامل‌های داخلی گلخانه و متغیرهای بیرونی را بدهد (Haykin, 1994). استفاده از این ابزار قادر است کشاورز را از افزایش گرمای تابستانه و یا کاهش بیش از حد دما در زمستان آگاه سازد (Hornik *et al.*, 1989; Seginer, Acosta & Tosini, 2001 ; 1997). مطالعات متنوعی در زمینه‌ی استفاده از شبکه‌های عصبی در گلخانه انجام شده است که از آن جمله می‌توان به کنترل شرایط محیط داخل گلخانه (Van Henten, 1994)، مدل سازی فیزیکی گلخانه (Dariouchy *et al.*, 2009) و تخمین یا پیش‌بینی برخی پارامترهای داخلی گلخانه اشاره کرد (Arahal ; Boaventura Cunha *et al.*, 2000; Linker & *et al.*, 2005 Seginer, 2004). در تحقیقی از شبکه‌های عصبی مصنوعی به منظور ابزاری برای جایگزین کردن انواع حسگرها در گلخانه ای در کشور پرتقال استفاده شد (Ferreira *et al.*, 2002). در این مطالعه به منظور تخمین دمای هوای داخل گلخانه، از پارامترهایی مانند میزان تابش ورودی به گلخانه، دمای هوای بیرون و همچنین رطوبت نسبی هوای داخل گلخانه استفاده شد. نتایج نشان داد که استفاده از این ابزار به درستی قادر است مقدار تغییرات دمای هوای داخل گلخانه‌ای با کشت هیدروپونیک را تخمین بزند ولی به منظور افزایش دقت و همچنین کاهش خطر مواجه شدن با نوسانات دمایی شدید، وجود حسگرهایی با دقت متوسط و به تعداد کم در گلخانه توصیه می‌شود. این روش می‌تواند در آینده و با پیشرفت بیش‌تر علوم، به عنوان جایگزینی برای انواع دماسنج‌ها و حسگرهای پرهزینه در انواع گلخانه‌ها مورد استفاده قرار گیرد. Dariouchy *et al.*, (2009)، از مدل شبکه عصبی و مدل‌های رگرسیونی برای پیش بینی رطوبت نسبی و دمای هوای داخل گلخانه‌ای در مراکش استفاده کردند. در این تحقیق، رطوبت نسبی هوای بیرون از گلخانه، شدت تابش خورشید در سطح افق، جهت و سرعت باد و دمای هوای خروجی به عنوان متغیرهای ورودی و دما و درصد رطوبت داخلی گلخانه به عنوان خروجی مدل در نظر گرفته شد. نتایج نشان داد که استفاده از ابزار شبکه عصبی قادر است نتایج بهتری نسبت به انواع مدل‌های رگرسیونی مرسوم نشان دهد. مقدار خطا در پیش‌بینی دما و رطوبت نسبی داخلی گلخانه در این تحقیق، به ترتیب ۴/۲۳ و ۳/۸۵ درصد گزارش شد (Makarian, 2013).

تخمین دما و رطوبت هوای داخل گلخانه، تحت تأثیر شرایط مختلف محیطی و سامانه‌های متنوع تهویه، گامی مهم در راستای طراحی و انتخاب تجهیزات سرمایشی-گرمایشی و همچنین هوشمندسازی کنترل شرایط گلخانه محسوب می‌شود. از این رو، در تحقیق حاضر پیش‌بینی دمای هوای داخل گلخانه در حالت‌های بدون تهویه و با سامانه‌ی خنک‌کننده‌ی تبخیری با استفاده از دو روش رگرسیونی چندگانه و شبکه‌های عصبی مصنوعی، به‌عنوان ابزارهایی نیرومند برای شبیه‌سازی پدیده‌های پیچیده‌ی تجربی، مورد نظر قرار گرفت.

مواد و روش‌ها

مشخصات گلخانه

از یک گلخانه با ساختار یک‌طرفه، برای انجام آزمایش‌های تحقیق استفاده شد. ارتفاع دیواره‌ی جنوبی گلخانه کوتاه‌تر از دیواره شمالی آن بود تا سقف گلخانه شیب‌دار (با زاویه ۳۰ درجه برابر با عرض جغرافیایی محل انجام آزمایش) باشد. این گلخانه به طول ۵ متر، عرض ۲/۱۶ متر با ارتفاع دیوار جنوبی ۱/۵ متر و شمالی ۲/۷۵ متر، در آزمایشگاه انرژی خورشیدی بخش مهندسی مکانیک بیوسیستم دانشگاه شهید باهنر کرمان ساخته شد (موقعیت جغرافیایی: N ´30/14، E ´57/06 و ارتفاع از سطح دریا ۱۷۵۶ متر). شاسی گلخانه از قوطی‌های فولادی با سطح مقطع ۴×۴ سانتی‌متر بود که سطح بیرونی آن توسط ورق‌های پلی‌کربنات شفاف با ضخامت ۱۰ میلی‌متر پوشیده شد (شکل ۱- الف).

الف

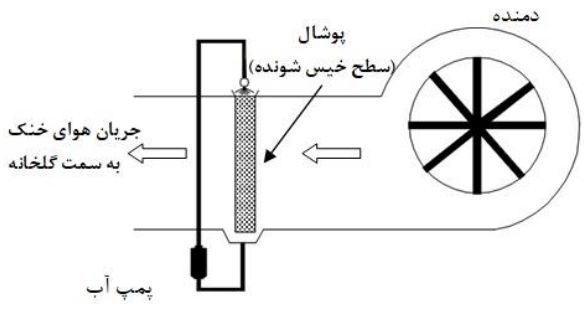

ب

شکل ۱. الف) گلخانه با سامانه سرمایش تبخیری استفاده شده در تحقیق و ب) طرحواره ای از اجزای سامانه سرمایش تبخیری

سامانه سرمایش استفاده شده در تحقیق شامل یک دمنده گریز از مرکز با توان نامی ۵۶۰ وات، پوشال (سطح خیس شونده)، پمپ و لوله برگشت آب بود (شکل ۱-ب). برای انجام آزمایش‌های تحقیق، از سرعت دمنده ۳۰۴ دور بر دقیقه و ضخامت پوشال ۴ سانتی‌متر استفاده گردید. آزمایش‌ها در دو حالت بدون سامانه سرمایش و با استفاده از سامانه سرمایش تبخیری، در روزهای ۲۷ دی تا ۱۷ اسفند ۹۵ انجام شد. هر آزمایش از ساعت ۹ صبح شروع و تا ۵ عصر، ادامه می‌یافت. پارامترهای اندازه‌گیری شده در هر آزمایش شامل، دمای محیط گلخانه در سه نقطه و محیط اطراف آن، همچنین دمای دیواره شمالی و هوای ورودی به گلخانه توسط سامانه سرمایش و شدت تابش ورودی به گلخانه بودند.

نحوه جمع آوری داده‌ها

برای اندازه‌گیری شدت تابش خورشید از یک دستگاه سولارمتر با دقت یک وات بر مترمربع (مدل TES 1333 R، شرکت TES، ساخت تایوان) و برای اندازه‌گیری دما در نقاط مختلف از حسگرهای دما مدل SMT 160 با دقت ۰/۱ درجه سلسیوس متصل به یک ترانسمیتر دما مدل TM-1323 (ساخت شرکت مهندسی تیکا در ایران) استفاده شد. رطوبت داخل و بیرون گلخانه با استفاده از رطوبت سنج‌های (مدل SUN-25H، شرکت SUNWARD) با دقت ۱ درصد تعیین گردید. برای اندازه‌گیری سرعت باد از یک سرعت سنج پره‌ای (مدل BE816A، شرکت BESTONE) با دقت ۰/۱ متر بر ثانیه استفاده شد.

روش شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی به عنوان یک رویکرد جدید از مدل-های غیر خطی، برای پیش‌بینی دمای هوای داخل گلخانه در نظر گرفته شد. شبکه‌های عصبی زیست‌شناختی مغز انسان شامل مجموعه‌ای از واحدهای عصبی به نام نرون هستند که با رابط‌هایی موسوم به آسه (آکسون) به هم متصل شده‌اند. یک نرون مصنوعی، مدل ریاضی ساده شده یک عصب زیستی است. عملیاتی که در هر نرون صورت می‌گیرد به این صورت است که نرون، همه ورودی‌هایی که به سلول رسیده است را جمع می‌کند، آن را از یک تابع محرک عبور می‌دهد و در نهایت خروجی نرون را ایجاد می‌کند (Sabziparvar, 2014). شبکه‌های عصبی مصنوعی از جمله سامانه‌های دینامیکی می‌باشند که با پردازش داده‌های تجربی، قانون نهفته در ورای اطلاعات را به ساختار شبکه منتقل می‌کنند، به همین خاطر آن‌ها را سامانه‌های هوشمند نیز می‌نامند (Jain *et al.*, 1999). ساختار عمومی مدل‌های شبکه عصبی مصنوعی متشکل از سه لایه شامل لایه ورودی، که در این لایه اطلاعات ورودی به مدل معرفی می‌شوند، لایه یا لایه‌های مخفی، که اطلاعات در این لایه پردازش می‌گردد و لایه خروجی که نتایج حاصل از عملکرد مدل تولید در آن می‌شود. ساختار یک شبکه عصبی مصنوعی با تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تابع محرک، روش آموزش، الگوریتم تصحیح وزن‌ها و نوع مدل، تعیین می‌گردد (Karimi *et al.*, 2013). متداول‌ترین شبکه عصبی مصنوعی، شبکه پرسپترون چند لایه[1] می‌باشد (Hecht-Nielsen, 1987). با توجه به اینکه طی سال‌های اخیر، شبکه عصبی پرسپترون چندلایه به‌خوبی قابلیتش را در شبیه‌سازی و پیش‌بینی پارامترهای اقلیمی و هواشناسی متفاوت نشان داده است (Azadeh *et al.*, 2009)، در این تحقیق نیز یک نمونه از شبکه‌های چندلایه پرسپترون مورد استفاده قرار گرفت. شبکه‌های عصبی مصنوعی چند لایه پیشخور راه حل مناسبی برای پیش‌بینی محسوب می‌شوند. برای آموزش شبکه از پرسپترون چندلایه با الگوریتم یادگیری پس‌انتشار خطا[2] استفاده گردید و تابع‌های فعالیت در لایه‌های مخفی برای تمام شبکه‌ها از نوع تابع انتقال غیرخطی tansig و از تابع خطی purelin در لایه خروجی، در نظر گرفته شد. اگر تعداد نرون‌ها در لایه‌ی پنهان کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن‌ها، مسئله بیش برازشی[3] بوجود خواهد آمد که این منجر به ضعیف شدن ویژگی تعمیم پذیری شبکه می‌شود (Wang & Elhag, 2007). در این تحقیق از شبکه‌های عصبی پرسپترون چند لایه با روش یادگیری پس‌انتشار خطا استفاده شد. این شبکه‌ها به طور معمول به الگوریتم پس‌انتشار خطا مشهورند زیرا خطای خروجی مدل به عقب و به داخل سامانه برگردانده می‌شود تا تغییر و تنظیم وزن‌های لایه‌های پنهان انجام گیرد (Peyman, 2007). ورودی‌های شبکه برای حالت بدون سامانه سرمایش، شامل شدت تابش خورشید، دمای هوای محیط، دمای دیواره شمالی؛ و برای حالتی که از سامانه سرمایش تبخیری استفاده شد، علاوه بر این‌ها شامل دما و دبی هوای خنک‌کننده ورودی به گلخانه بودند. در هر دو حالت، خروجی شبکه دمای هوای داخل گلخانه می‌باشد (شکل ۲).

در این پژوهش، جمع‌آوری داده‌های آزمایش هر ۵ دقیقه

1. Multi-layer perceptron
2. Back propagation
3. Over-fitting

یک بار در طول روز بود. در نهایت، از مجموع داده‌های جمع-آوری شده ۷۰ درصد برای آموزش، ۱۵ درصد برای آزمایش و ۱۵ درصد دیگر برای اعتبارسنجی شبکه مورد استفاده قرار گرفتند. به‌منظور تحلیل روش شبکه عصبی از نرم‌افزار MATLAB نسخه ۲۰۱۵ استفاده گردید.

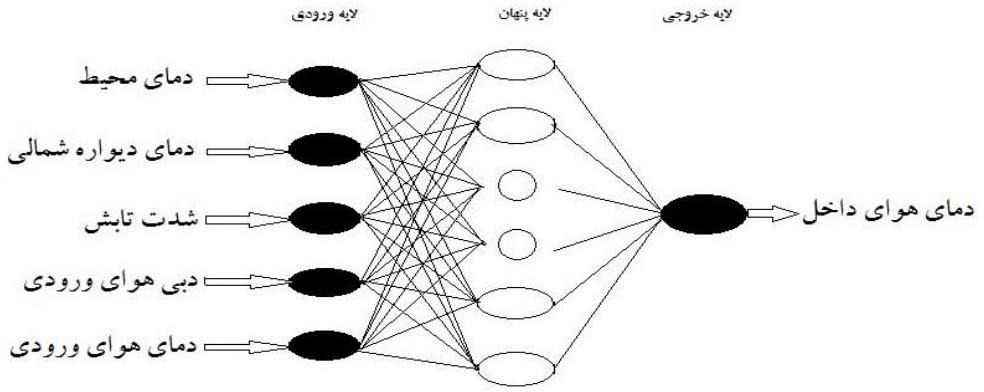

شکل ۲. ساختارشبکه عصبی مصنوعی چندلایه پرسپترون مورد استفاده در تحقیق

قبل از به‌کارگیری داده‌های خام اولیه برای آموزش در شبکه، داده‌ها باید در دامنه مناسبی نرمال شوند. دلیل این امر آن است که الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد خوبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئید (۱ - ۰) به‌کارگرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد. در صورت نرمال نکردن داده‌ها، شبکه در طول فاز آموزش هم‌گرا نخواهد شد و نتایج مطلوب حاصل نمی‌گردد. زمانی‌که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها (۰/۹ - ۰/۱) می‌باشد.به طورمعمول از معادله زیر برای نرمال کردن داده‌ها استفاده می‌گردد .

$$Xn = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad \text{(رابطه ۱)}$$

که در آن X داده خام اولیه، Xn داده نرمال شده، X_{max} و X_{min} به‌ترتیب مقدارهای بیشینه و کمینه داده‌های اولیه، r_{max} و r_{min} به‌ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است. داده‌های نرمال شده توسط الگوریتم‌های آموزش لونبرگ مارکوارت[1] (LM)، تنظیم به‌روش بیزی[2] (BR) و اسکالت کانژوگیت گرادینت[3] (SCG) مورد آموزش قرار گرفتند. براساس مطالعات صورت گرفته در ادبیات پیشین، الگوریتم تنظیم به-روش بیزی به دلیل استفاده از مدل ریاضی بیز، در حل الگوریتم دارای دقت بالا و الگوریتم اسکالت کانژوگیت گرادینت با کاهش دوره آموزش باعث کم شدن منحنی خطا و درنتیجه افزایش سرعت الگوریتم در حل می‌شود (Saini, 2008 ; Moller, 1993). براساس یک قانون جهانی، به طور معمول، مناسب‌ترین شبکه‌ها با تعداد یک لایه پنهان مشخص می‌شوند (Dariouchy *et al.*, 2009). به همین دلیل در این تحقیق تمامی داده‌ها با شبکه‌ای با ساختار شامل یک لایه‌ی پنهان، مورد آزمایش قرار گرفتند.

مدل‌سازی با روش رگرسیون چندگانه خطی

در این تحقیق مدل‌سازی رگرسیونی چندگانه با روش شبکه عصبی مصنوعی مورد مقایسه قرار گرفت. ابتدا از پارامترهای اندازه‌گیری شده در درون و بیرون محیط گلخانه که شامل دمای هوای محیط، دمای دیواره شمالی، شدت تابش، دبی هوای ورودی و دمای هوای ورودی برای پیش‌بینی دمای داخل گلخانه و استخراج معادلات رگرسیونی استفاده شد. سپس از روش پیشرو[4] و پسرو[5] برای تعیین معادلات رگرسیونی با تعداد متغیر مستقل کمتر ولی با همان دقت به کار برده شد. رابطه زیر به منظور استفاده از مدل رگرسیونی مورد استفاده قرار گرفت:

$$Y = \beta_0 + \beta_r \sum X_r \quad \text{(رابطه۲)}$$

در این رابطه، β_0 مقدار ثابت عرض از مبدا، X_r متغیرهای مستقل و β_r مقدار ضریب‌های آن‌هاست. به منظور تحلیل مدل رگرسیونی از نرم افزار SPSS نسخه ۱۵ استفاده شد. به منظور ارزیابی توانائی و دقت شبکه عصبی و مدل رگرسیونی در پیش بینی دمای هوای داخل گلخانه از معیارهای آماری میانگین مربعات خطا[6] (MSE)، ضریب همبستگی[7] (R^2) و متوسط قدر

1 . Levenberg-Marquart algorithm
2 . Bayesian regularization
3 . Scaled conjugate gradient

4. Forward
5. Backward
6. Mean squared error
7. Correlation coefficient

مطلق خطا[1] (MAPE) استفاده شد که با رابطه‌های ۳ تا ۵ محاسبه گردیدند.

(رابطه ۳) $$R^2 = \frac{[\sum(d_j - \bar{d})(p_i - \bar{p})]^2}{\sum(d_j - \bar{d})^2 \times \sum(p_i - \bar{p})^2}$$

(رابطه۴) $$MSE = \frac{\sum(d_j - p_i)^2}{n}$$

(رابطه۵) $$MAPE = \frac{1}{n}\sum\frac{(d_j - p_i)}{d_j}$$

که در آن، d_j مولفه j ام از داده‌های واقعی مربوط به الگوی j ام، p_i مولفه i ام از خروجی پیش‌بینی شده مربوط به الگوی i ام، $\bar{d}$ و $\bar{p}$ به‌ترتیب متوسط خروجی‌های واقعی و پیش‌بینی شده و n تعداد الگوهای خروجی است.

1 . Mean absolute percentage error

نتایج

در این تحقیق، داده‌ها توسط الگوریتم‌های آموزش لونبرگ مارکوارت، تنظیم به‌روش بیزی و اسکالت کانژوگیت گرادینت مورد آموزش قرار گرفتند. مشخصه‌های آماری پارامترهای تجربی مورد استفاده در ساختار شبکه عصبی مصنوعی، برای حالت بدون سامانه‌ی سرمایش در جدول ۱ و برای حالت با سامانه‌ی سرمایش تبخیری، در جدول ۲ مشاهده می‌گردد.

جدول ۳ نتایج عملکرد شبکه‌های عصبی آزمون شده برای حالت‌هایی که از الگوریتم‌ها و نرون‌های مختلف استفاده شده، را نشان می‌دهد.

جدول ۱. مشخصه‌های آماری داده‌های تجربی در حالت بدون تهویه

پارامترها	میانگین	حداقل	حداکثر	انحراف معیار
شدت تابش خورشید (وات بر مترمربع)	۶۹۰/۳	۱۳۵/۹	۹۰۹/۸	۲۱۹/۸۸۰
دمای محیط (درجه سلسیوس)	۱۸/۵	۱۵/۴	۲۳/۶	۲/۰۰
دمای گلخانه (درجه سلسیوس)	۴۶/۶	۳۳/۶	۵۲/۹	۵/۶۰۱
دمای دیواره شمالی (درجه سلسیوس)	۱۲/۵	۱۰/۹	۱۳/۶	۰/۶۹۷

جدول ۲. مشخصه‌های آماری داده‌های تجربی در حالت سامانه سرمایش تبخیری

پارامترها	میانگین	حداقل	حداکثر	انحراف معیار
شدت تابش خورشید (وات بر مترمربع)	۸۶۹/۳	۸۲۸/۲	۸۸۸/۵	۱۹/۰۴۳
دمای محیط (درجه سلسیوس)	۲۰/۰	۱۷/۱	۲۹/۷	۳/۰۱۹
دمای گلخانه (درجه سلسیوس)	۲۵/۱	۲۰/۷	۳۵/۷	۳/۹۸۴
دمای هوای ورودی به گلخانه (درجه سلسیوس)	۱۷/۵	۱۶/۲	۱۹/۷	۰/۹۴۰
دبی هوای ورودی به گلخانه (متر مکعب بر ثانیه)	۱/۱۴	۱/۱۴	۱/۱۴	۰/۰

با توجه به جدول، برای تعیین دمای هوای داخل گلخانه و با توجه به شاخص‌های ارزیابی می‌توان گفت در الگوریتم LM با افزایش نرون‌ها نتایج شبکه عصبی بهتر می‌شود ولی در حالت BR با افزایش نرون‌ها شبکه عصبی از حالت ایده آل خود خارج شده و در نهایت برای حالت SCG از الگوی خاصی پیروی نمی‌کند. در کل با توجه به نتایج به دست آمده از میانگین مربعات خطا، ضریب تبیین و متوسط قدرمطلق خطا می‌توان گفت مناسب‌ترین پیش‌بینی دمای داخل گلخانه در حالت بدون سامانه‌ی سرمایش، به‌وسیله‌ی الگوریتم آموزشی BR با ۶ نرون در لایه‌ی میانی بدست آمد. بعلاوه، الگوریتم LM با تعداد ۱۴ نرون در لایه‌ی میانی بهترین تخمین را برای دمای گلخانه در حالت مجهز به سامانه‌ی سرمایش تبخیری ارائه کرد. همان طور که در شکل ۳ مشخص است مقدارهای تجربی و تئوری در نزدیکی خط با شیب واحد قرار دارند، که نشان از مناسب بودن مدل رگرسیونی برای پیش‌بینی داده‌ها دارد.

مدل رگرسیونی

جدول ۴ مدل‌های رگرسیونی برای تخمین هوای داخل گلخانه در هر دو حالت بدون تهویه و با سامانه‌ی سرمایش تبخیری را نشان می‌دهد. خروجی مدل‌ها، دمای هوای داخل گلخانه (T_a) بر حسب درجه سلسیوس است که بر اساس ورودی‌ها، به‌ترتیب شامل، دمای محیط (T_o)، دمای دیواره شمالی (T_{nw}) بر حسب درجه سلسیوس، شدت تابش خورشید (R) بر حسب وات بر متر مربع، دبی هوای ورودی (Q) بر حسب کیلوگرم بر ثانیه و دمای هوای ورودی (T_v) بر حسب درجه سلسیوس می‌باشد. تمام

ضریب‌ها در رابطه‌های رگرسیونی این جدول، در سطح احتمال ۵٪ معنی دار هستند. با توجه به جدول می‌توان گفت، در حالت بدون تهویه، با افزایش دو درجه‌ی سلسیوس دمای محیط و ۱۰۰ وات بر متر مربع، شدت تابش خورشید، با فرض ثابت ماندن دمای دیوار شمالی، دمای گلخانه حدود ۲/۸۵ درجه‌ی سلسیوس افزایش می‌یابد. در حالی که، در حالت با سامانه‌ی سرمایش تبخیری، این مقدار افزایش در دمای محیط و شدت تابش خورشید، موجب زیاد شدن دمای گلخانه تا حدود ۰/۰۷۶ درجه‌ی سلسیوس می‌شود.

جدول ۳ . نتایج عملکرد شبکه‌های عصبی آزمون شده برای حالت‌های مختلف

پارامتر اندازه‌گیری‌شده	الگوریتم آموزش	نرون‌های لایه میانی	میانگین مربعات خطا	ضریب تبیین	متوسط قدر مطلق خطا
دمای هوای داخل گلخانه بدون سامانه سرمایش	LM*	۶	۰/۰۰۰۳۸۵	۰/۹۸۷۷۷۶	۰/۰۳۸۰۹۸
		۱۴	۰/۰۰۲۶۸۶	۰/۹۹۳۸۶۴	۰/۲۸۲۶۸۳
		۲۰	۰/۰۰۰۲۹۹	۰/۹۹۳۱۶۳	۰/۰۴۷۹۳۵
	BR**	۶	۰/۰۰۰۱۵	۰/۹۹۲۳۱۳	۰/۰۲۵۱۵۴
		۱۴	۰/۰۰۰۲۹۴	۰/۹۹۱۱۰۹	۰/۰۲۴۳۴۵
		۲۰	۰/۰۰۰۷۴۳	۰/۹۸۹۳۲۱	۰/۰۵۶۹۳۲
	SCG***	۶	۰/۰۰۴۹۶	۰/۹۶۳۷۶۹	۰/۷۰۸۲۹۵
		۱۴	۰/۰۰۲۴۸	۰/۸۶۸۱۸۴	۰/۱۸۷۴۴۲
		۲۰	۰/۰۰۰۳۸۷	۰/۹۵۵۶۰۶	۰/۰۱۳۹۹۰
دمای هوای داخل گلخانه با استفاده از سامانه سرمایش تبخیری	LM	۶	۰/۰۰۲۳۵	۰/۹۷۳۸۵۲	۰/۴۱۴۳۳۱
		۱۴	۰/۰۰۱۵۸	۰/۹۸۵۷۵۱	۰/۲۱۴۳۸۳
		۲۰	۰/۰۰۱۳۶۶	۰/۹۵۴۱۰۳	۰/۰۹۳۵۷۶
	BR	۶	۰/۰۰۰۹۷۱	۰/۸۵۵۵۱	۰/۱۸۱۱۵۰
		۱۴	۰/۰۰۵۱۳۱	۰/۸۴۶۲۲۶	۰/۴۳۸۷۹۴
		۲۰	۰/۰۰۰۱۵۶	۰/۸۶۰۷۰۳	۰/۳۲۸۱۶۱
	SCG	۶	۰/۰۰۳۳	۰/۸۱۸۵۷۱	۰/۷۶۶۷۱۳
		۱۴	۰/۰۰۴۴۳	۰/۸۹۱۴۴۶	۰/۷۵۹۰۳۰
		۲۰	۰/۰۰۰۶۶۲	۰/۷۹۰۷۲۲	۰/۲۶۸۶۴۶

*. الگوریتم لونبرگ مارکوارت[1]، **. الگوریتم تنظیم به‌روش بیزی[2]، ***. الگوریتم اسکالت کانژوگیت گرادینت[3]

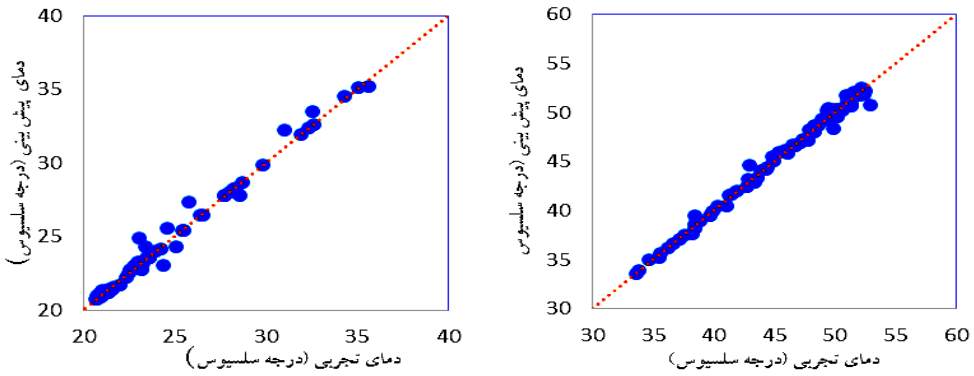

شکل ۳. همبستگی دمای هوای گلخانه تجربی و شبیه‌سازی شده (الف) در حالت بدون تهویه با استفاده از شبکه با ساختار BR با ۶ نرون در لایه میانی (ب) با سامانه سرمایش تبخیری با استفاده از شبکه از شبکه با ساختار LM با ۱۴نرون در لایه‌ی میانی

1 Levenberg marquart
2 Bayesian Regularization
3 Scaled Conjugate Gradient

جدول ۴. مدل رگرسیونی بدست آمده برای پیش‌بینی هوای داخل گلخانه

معادلات رگرسیونی	حالت
$Ta = 0.025To + 5.126Tnw + 0.028R - 36.889$	بدون تهویه
$Ta = 1.8Tv + 0.738To - 257.009Q - 0.014R + 283.809$	با سامانه سرمایش تبخیری

جدول ۵ نتایج ارزیابی مدل‌های رگرسیونی را نشان می‌دهد. با توجه به جدول میانگین مربعات خطا، ضریب تبیین و معیار متوسط قدر مطلق خطا به ترتیب بین ۱/۱۳۵ تا ۱/۳۶۴، ۰/۹۳ تا ۰/۹۷ و ۰/۰۳۱۳۰۹ تا ۱/۴۸۲۰۳ بود. از مقایسه‌ی ضریب همبستگی، ضریب تبیین و میانگین مربعات خطا بین مدل رگرسیونی و شبکه عصبی می‌توان به این نتیجه رسید که شبکه عصبی قابلیت بهتری در پیش بینی دمای هوای داخل گلخانه را دارد.

برای درک بهتر عملکرد مدل رگرسیونی، پراکندگی داده‌های خروجی در مقابل داده‌های تجربی در شکل ۴ نشان داده شده است. همان گونه که مشاهده می‌شود تمام داده‌ها در نزدیکی خط با شیب واحد قرار دارند.

جدول ۵. نتایج ارزیابی مدل‌های رگرسیونی بدست‌آمده در تحقیق

پارامتر اندازه‌گیری‌شده دمای هوای داخل گلخانه	میانگین مربعات خطا	ضریب تبیین	معیار متوسط قدر مطلق خطا
بدون سامانه سرمایش	۱/۱۳۵	۰/۹۷۰	۰/۰۳۱۳۰۹
سامانه سرمایش تبخیری	۱/۳۶۴	۰/۹۳۰	۱/۴۸۲۰۳

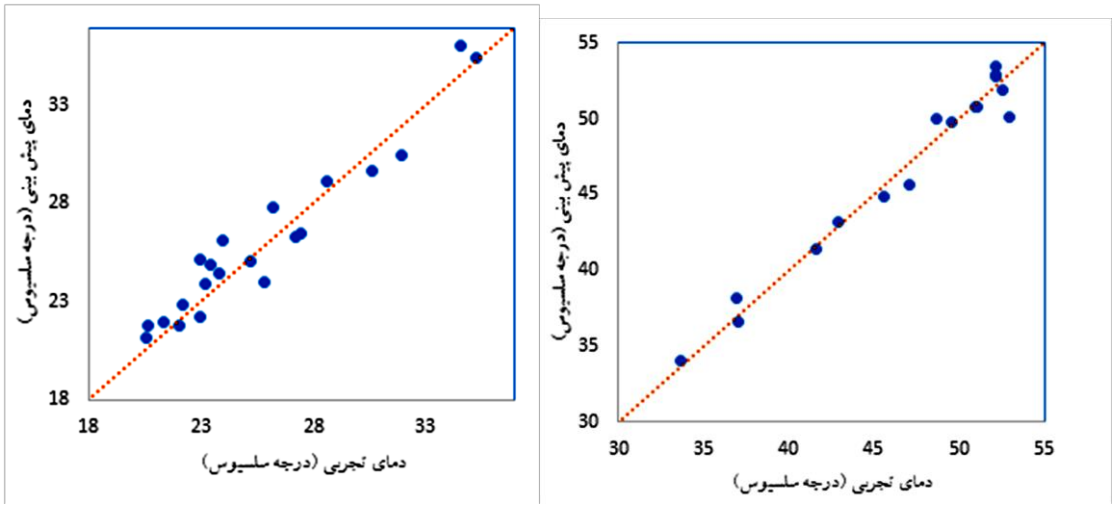

(الف) (ب)

شکل ۴. همبستگی دمای هوای گلخانه تجربی و شبیه‌سازی شده با مدل رگرسیونی (الف) در حالت بدون تهویه (ب) با سامانه سرمایش تبخیری

در تحقیقی دما و درصد رطوبت داخلی گلخانه بر اساس رطوبت هوای بیرون از گلخانه، شدت تابش خورشید در سطح افق، جهت و سرعت باد و دمای هوای خروجی، با دو روش رگرسیونی و شبکه عصبی مصنوعی پیش‌بینی شد. نتایج نشان داد که عملکرد شبکه عصبی از مدل‌های رگرسیونی بیش‌تر است. بعلاوه، ضریب همبستگی بین داده‌های واقعی و پیش بینی شده توسط مدل رگرسیونی برای دمای هوا و رطوبت نسبی داخلی گلخانه به ترتیب معادل ۰/۹۶۵ و ۰/۹۷۸ گزارش گردید (Dariouchy *et al.*, 2009). جودی و فرهان (Joudi & Farhan, 2015) به پیش بینی دمای هوای داخل و خاک یک گلخانه در عراق پرداختند. پارامترهای ورودی برای مدل پیشنهادی، شرایط آب و هوای محیط و خواص ترموفیزیک اجزای گلخانه شامل پوشش، هوای داخل و خاک، بودند. نتایج حاصل از مدل با نتایج تجربی همخوانی داشتند و خطای مطلق بین داده‌ها بیش از ۱۰٪ بود، در صورتی که خطای مطلق بین داده‌های تئوری و تجربی در تحقیق حاضر کمتر از ۲% می-

باشد. در تحقیقی دیگر که توسط دوو و همکاران انجام شد، نتایج تخمین دمای هوای داخل گلخانه مجهز به پمپ حرارتی، با روش مدل حرارتی نشان داد که خطای محاسبات بیش از ۲۰٪ بود (Du *et al.*, 2012).

همان‌طور که از شکل ۳ و ۴ پیداست، اختلاف کم بین داده‌های تجربی و داده‌های شبیه‌سازی شده با روش شبکه عصبی مصنوعی، موجب قرارگیری تمام داده‌ها، با فاصله نزدیک‌تر در اطراف خط با شیب یک گردیده است. این امر، حاکی از عملکرد بهتره شبکه عصبی نسبت به مدل رگرسیونی می‌باشد.

نتیجه‌گیری

در تحقیق حاضر، مدل‌سازی دمای هوای داخل گلخانه در دو حالت بدون تهویه و با سامانه‌ی سرمایش تبخیری، با دو روش - شبکه عصبی مصنوعی و رگرسیونی انجام شد. ساختار شبکه، در حالت بدون تهویه، دارای سه ورودی شامل شدت تابش خورشید، دمای هوای محیط و دمای دیواره شمالی و در حالتی که از سامانه سرمایش تبخیری استفاده گردید دارای پنج ورودی شامل شدت تابش خورشید، دمای دیوار شمالی و هوای محیط، دبی و دمای هوای ورودی بودند. برای آموزش شبکه از پرسپترون چندلایه با الگوریتم یادگیری پس‌انتشار خطا و مدل رگرسیونی استفاده شد و از الگوریتم‌های آموزش لونبرگ مارکوارت، تنظیم به‌روش بیزی و اسکالت کانژوگیت گرادینت استفاده گردید. توابع فعالیت در لایه‌های مخفی برای تمام شبکه‌ها از نوع تابع انتقال غیرخطی tansig و از تابع خطی purelin در لایه خروجی، در نظر گرفته شد. با توجه به نتایج بدست آمده، می‌توان بیان نمود که استفاده از شبکه عصبی مصنوعی به‌عنوان یک ابزار شبیه‌سازی غیرخطی، توانایی پیش‌بینی دمای هوای داخل گلخانه، تحت تأثیر عامل‌های مختلف کاری را دارا می‌باشد. در پیش بینی دمای هوای داخل گلخانه در حالت بدون تهویه و سامانه سرمایش تبخیری به ترتیب الگوریتم‌های BR با ۶ نرون و LM با ۱۴ نرون بهتر بودند. نتایج مدل‌سازی رگرسیونی حاکی از آن بود که، در حالت بدون تهویه، با افزایش یک درجه‌ی سلسیوس در دمای محیط و ۱۰۰ وات بر متر مربع، شدت تابش خورشید، با فرض ثابت ماندن دمای دیوار شمالی، دمای گلخانه حدود ۳ درجه‌ی سلسیوس افزایش می‌یابد. مقایسه‌ی آماری پیش‌بینی‌های انجام شده نشان داد که شبکه‌های عصبی مصنوعی با دقت بالاتری نسبت به مدل رگرسیونی، قادر به تخمین دمای هوای داخل گلخانه هستند.

REFERENCES

Acosta, G. & Tosini, M., (2001). A firmware digital neural network for climate prediction applications, Intelligent Control, 2001.(ISIC'01). *Proceedings of the 2001 IEEE International Symposium on. IEEE*. 127-131.

Arahal, M. R., Rodriguez, F., Ramirez-Arias, A. & Berenguel, M., (2005). Discrete-time nonlinear FIR models with integrated variables for greenhouse indoor temperature simulation, *Decision and Control, 2005 and 2005 European Control* Conference. CDC-ECC'05. 44th IEEE Conference on. IEEE. 4158-4162.

Azadeh, A., Maghsoudi, A. & Sohrabkhani, S. (2009). An integrated artificial neural networks approach for predicting global radiation. *Energy Conversion and Management*, 50(6), 1497-1505.

Boaventura Cunha, J., Couto, C. & Ruano, A., (2000). *A greenhouse climate multivariable predictive controller*, International Conference and British-Israeli Workshop on Greenhouse Techniques towards the 3rd Millennium 534. 269-276.

Dariouchy, A., Aassif, E., Lekouch, K., Bouirden, L. & Maze, G. (2009). Prediction of the intern parameters tomato greenhouse in a semi-arid area using a time-series model of artificial neural networks. *Measurement*, 42(3), 456-463.

Dodange, M., (2011). *Evaluation and evaluation of solar greenhouses against fossil greenhouses*, Faculty of Economics and Accounting. Islamic Azad University, Central Tehran Branch.

Du, J., Bansal, P. & Huang, B. (2012). Simulation model of a greenhouse with a heat-pipe heating system. *Applied energy*, 93, 268-276.

Ferreira, P., Faria, E. & Ruano, A. (2002). Neural network models in greenhouse air temperature prediction. *Neurocomputing*, 43(1), 51-75.

Haykin, S. (1994). Neural networks: A comprehensive foundation: Macmillan college publishing company. *New York*.

Hecht-Nielsen, R., (1987). Kolmogorov's mapping neural network existence theorem, Proceedings of the international conference on *Neural Networks*. New York: IEEE Press. 11-13.

Hornik, K., Stinchcombe, M. & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, (5), 2359-2366.

Jain, S., Das, A. & Srivastava, D. (1999). Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resources Planning and Management*, 125(5), 263-271.

Joudi, K. A. & Farhan, A. A. (2015). A dynamic model and an experimental study for the internal air and soil temperatures in an innovative greenhouse. *Energy Conversion and Management*, 91, 76-82.

Karimi, S., Kisi, O., Shiri, J. & Makarynskyy, O. (2013). Neuro-fuzzy and neural network techniques for forecasting sea level in Darwin Harbor, Australia. *Computers & Geosciences*, 52, 50-59.

Linker, R. & Seginer, I. (2004). Greenhouse temperature modeling: a comparison between sigmoid neural networks and hybrid models. *Mathematics and computers in simulation*, 65(1), 19-29.

Makarian, H. a. R., A (2013). Prediction of Spatial Distribution Pattern of Acroptilon repens L. Population Using Learning Vector Quantization Neural Network Model *Knowledge of agriculture and sustainable production*, 23(1), 85-98.

Marcos, S., Macchi, O., Vignat, C., Dreyfus, G., Personnaz, L. & Roussel-Ragot, P. (1992). A unified framework for gradient algorithms used for filter adaptation and neural network training. *International journal of circuit theory and applications*, 20(2), 159-200.

Møller, Martin Fodslette. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, *6*(4), 525-533

Omid, M. & Shafaei, A. (2004). Investigation of temperature and humidity variations within a greenhouse using a computer-based data acquisition system pajouhesh-va-sazandegi, 17(3), 67-73. (In Farsi)

Peyman, M. a. M., A, H, (2007). Experimental criteria for determining the appropriateness of using multi-layered perceptron neural network to classify patterns, *First Iranian Data Mining Conference.*

Sabziparvar, A., A and Khataar, B (2014). Evaluation of Artificial Neural Network (ANN) and Irmak Experimental Models to Predict Daily Solar Net Radiation (Rn) in Cold Semi-arid Climate (Case study: Hamedan). *Water and soil knowledge*, 25(2), 37-50.

Seginer, I. (1997). Some artificial neural network applications to greenhouse environmental control. *Computers and Electronics in Agriculture*, 18(2-3), 167-186.

Saini, Lalit Mohan. (2008). Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks. *Electric Power Systems Research*, 78(7), 1302-1310.

Van Henten, E., (1994). Greenhouse climate management: an optimal control approach. Van Henten, Place: Published.

Wang, Y.-M. & Elhag, T. M. (2007). A comparison of neural network, evidential reasoning and multiple regression analysis in modelling bridge risks. *Expert Systems with Applications*, 32(2), 336-348.