

การทำนายค่าอุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าโดยใช้ระบบนิวโรฟัซซี่

Temperature and Relative Humidity Forecasting based on Neuro-Fuzzy System

หทัยเทพ วงศ์สุวรรณ

ศูนย์นวัตกรรมเมคคาทรอนิกส์และหุ่นยนต์ (IMERs)
ภาควิชาวิศวกรรมเครื่องกล(กำแพงแสน) คณะวิศวกรรมศาสตร์(กำแพงแสน)
มหาวิทยาลัยเกษตรศาสตร์(กำแพงแสน) จ.นครปฐม 73140
*ติดต่อ: โทรศัพท์: 034 355 310, โทรสาร: 034 355 310 E-mail: fenghtw@ku.ac.th

บทคัดย่อ

บทความนี้เป็นการนำเสนอวิธีการทำนายอุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าโดยใช้ระบบอัจฉริยะเช่นข่ายงานระบบประสาท ระบบนิวโรฟัซซี่ เพื่อประโยชน์ในการจัดการพลังงาน เนื่องจากอุณหภูมิและความชื้นสัมพัทธ์ในแต่ละวันมีการเปลี่ยนแปลงแบบไม่เป็นเชิงเส้น ทำให้ยากแก่การทำนายล่วงหน้า บทความนี้จึงได้นำเสนอตัวแบบพยากรณ์ค่าอุณหภูมิและความชื้นสัมพัทธ์โดยอาศัยปัจจัยพื้นฐานด้านอุณหภูมิ ค่าความชื้นสัมพัทธ์ ค่าปริมาณน้ำฝนและอื่นๆ ประกอบกัน และนำตัวแบบดังกล่าวเปรียบเทียบกับกันระหว่างข่ายงานระบบประสาท และระบบนิวโรฟัซซี่แบบ subtractive clustering ผลปรากฏว่าตัวแบบพยากรณ์ที่ใช้ระบบนิวโรฟัซซี่แบบ subtractive clustering ให้ค่าความถูกต้องในการทำนายล่วงหน้า 1 ชั่วโมง ดีที่สุดกว่าตัวแบบที่ใช้ระบบอัจฉริยะแบบอื่น โดยค่าได้ค่าความถูกต้องที่ 100% เปอร์เซนต์ จากผลการพยากรณ์ดังกล่าว สามารถประยุกต์ใช้ค่าอุณหภูมิและความชื้นสัมพัทธ์ในการคำนวณภาระความร้อนในอาคาร เพื่อนำไปประหยัดพลังงานได้

คำหลัก: ระบบนิวโรฟัซซี่ ระบบอัจฉริยะ ตัวแบบพยากรณ์ ความไม่เป็นเชิงเส้น

Abstract

The Temperature and relative humidity forecasting is the application of science and technology to predict the state of the temperature forecasts are made by collecting quantitative data about the current state of the atmosphere. This paper utilizes intelligence system for one step time interval ahead prediction of an important weather parameter which is temperature and relative humidity. Our study are forecasting temperature model based on Intelligence system such as Neural network and our proposed neuro-fuzzy which trained and tested using one year past(2010) weather data. We compared our forecasting model with another intelligence system. The results show that our proposed neuro-fuzzy has minimum forecasting error and can be considered as a good method for temperature and relative humidity forecasting. Thus, our proposed temperature and humidity forecasting model can be applied to calculating cooling load of building for energy management.

Keywords: Neuro-Fuzzy Intelligence System Forecasting Model Nonlinear

1. บทนำ

การพยากรณ์อากาศโดยใช้ข้อมูลสภาพอากาศเชิงตัวเลขได้มีการใช้มาตั้งแต่ 100 ปีก่อนโดยนาย Vilhelm Bjerknes [7] และได้มีการพัฒนาต่อมาในลักษณะของการหาสมการไม่เป็นเชิงเส้นโดยนำคอมพิวเตอร์เข้ามาช่วยในการประมวลผลข้อมูลที่มากขึ้น การที่สามารถทำนายอุณหภูมิล่วงหน้าได้อย่างถูกต้องนั้นสามารถนำไปประยุกต์ใช้ได้หลายเรื่องเช่นการทำนายสภาพอากาศ[8] การทำนายภาวะความร้อนในอาคาร[10] การทำนายพลังงานไฟฟ้า[6] การทำนายสภาพลม[9] เป็นต้น

ดังนั้นการล่วงรู้ถึงอุณหภูมิล่วงหน้าจึงมีความสำคัญต่องานวิจัยหลายๆงานที่พยายามจะทำนายอุณหภูมิล่วงหน้า เช่นงานของ Sara และคณะ [4] ได้นำวิธีการทางสถิติมาใช้หาอุณหภูมิที่ต่ำลงของรัฐแคลิฟอร์เนีย หลังจากนั้นเมื่อระบบอัจฉริยะมีการใช้งานที่แพร่หลายมากขึ้นอันเนื่องมาจากความก้าวหน้าทางเทคโนโลยีคอมพิวเตอร์ ทำให้มีนักวิจัยได้นำข่ายงานระบบประสาทใช้ทำนายค่าอุณหภูมิ [7,11]


ในบทความนี้ได้นำระบบอัจฉริยะแบบนิวโรฟซซีมาประยุกต์ใช้ในการทำนายอุณหภูมิล่วงหน้า 1 วัน โดยออกแบบตัวแบบพยากรณ์เพื่อทำนายอุณหภูมิล่วงหน้าของกรุงเทพมหานคร 1 ช่วงเวลา โดยใช้ข้อมูลในอดีตตั้งแต่ 1 มกราคม 2553 ถึง 30 เมษายน 2554 และทำการเปรียบเทียบผลการพยากรณ์เทียบกับข่ายงานระบบประสาท และระบบนิวโรฟซซีแบบอื่น

เนื้อหาของบทความนี้ประกอบไปด้วยบทที่ 1 กล่าวถึงที่มาและความสำคัญของงานวิจัยนี้ ส่วนในบทที่ 2 กล่าวถึงพื้นฐานโครงสร้างของระบบอัจฉริยะแบบต่างๆ บทที่ 3 กล่าวถึงการออกแบบตัวแบบพยากรณ์ ส่วนบทที่ 4 กล่าวถึงผลการทดลองของตัวแบบพยากรณ์ที่ออกแบบและบทที่ 5 เป็นการสรุปและข้อเสนอแนะสำหรับงานวิจัยนี้

2. ระบบอัจฉริยะสำหรับทำนายอุณหภูมิล่วงหน้า

2.1 ข่ายงานระบบประสาท (Neural Network)

ข่ายงานระบบประสาท ได้ถูกเสนอครั้งแรกในปี 1943 โดย McCulloch และ Pitts โดยเสนอโครงข่ายที่มีความสามารถในการตัดสินใจระดับบิต จากนั้นได้มีการพัฒนาโครงข่ายระบบประสาทนี้เรื่อยมาในปัจจุบัน ข่ายงานระบบประสาทนี้เป็นรูปแบบการจำลองระบบประสาทของมนุษย์ขึ้นมา โดยอาศัยหลักการต่อกันของสมการเป็นร่างแหและมีการปรับค่าสัมประสิทธิ์ของการต่อกัน รูปแบบข่ายงานระบบประสาทที่นิยมคือแบบหลายชั้นป้อนไปข้างหน้า (Multi-layer feedforward networks) ดังรูปที่ 1 [2] โครงสร้างแบบนี้อาศัยหลักการเรียนรู้แบบป้อนกลับ (backpropagation learning) ในการปรับค่าตัวแปรในโครงข่ายโดยอาศัยข้อมูลเดิมของระบบ (Supervise learning) นอกจากนี้ก็ยังมีวิธีการเรียนรู้แบบไม่มีผู้ช่วยสอน โดยอาศัยเฉพาะรูปแบบข้อมูลขาเข้าเท่านั้น โดยสรุปข่ายงานระบบประสาทนั้นใช้ในเรื่องของการจำลองระบบที่เราสนใจหรือสร้างระบบควบคุมโดยอาศัยชุดข้อมูลแบบเชิงตัวเลขในการปรับตัวและเรียนรู้



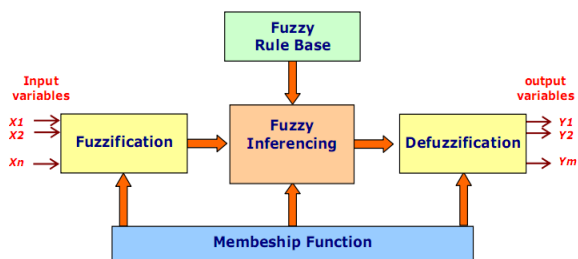
รูปที่ 1 แสดงแบบจำลองข่ายงานระบบประสาท

ข้อดีของข่ายงานระบบประสาทคือมีความสามารถในการประมาณค่าฟังก์ชันหรือความสัมพันธ์ของระบบหรือคู่ข้อมูลเข้าและออกจากระบบใดระบบหนึ่ง แต่ข้อเสียคือความถูกต้องของระบบขึ้นกับความถูกต้องของข้อมูลและถึงแม้ว่าข้อมูลจะถูกต้องแต่ก็เป็นการประมาณค่าความสัมพันธ์เท่านั้น ไม่ใช่ความถูกต้องที่แท้จริง นอกจากนี้ยังใช้เวลาในการเรียนรู้กลุ่มข้อมูลนาน ต้องเรียนรู้ใหม่ถ้าข้อมูลใหม่อยู่นอกกลุ่มข้อมูลเดิม

2.2 ตรรกศาสตร์คลุมเครือ(Fuzzy Logic)

ในปี 1965 Zadeh ได้เสนอทฤษฎีตรรกศาสตร์คลุมเครือ (Fuzzy Sets Theory) ขึ้นทำให้เราสามารถใช้รูปแบบเชิงคุณภาพในการอธิบายคุณลักษณะระบบที่

สนใจได้ ตรรกศาสตร์คลุมเครือใช้ตัวแปรเชิงบรรยายในการออกแบบจำลองระบบ ซึ่งตัวแปรเหล่านี้จะถูกแปลงจากปริมาณเชิงตัวเลข(Crisp Input) ให้อยู่ในรูปข้อมูลเชิงคลุมเครือ(Fuzzy Value) โดยใช้ฟังก์ชันสมาชิก (Membership function) เป็นตัวจัดการปริมาณเหล่านั้น จากนั้นถูกส่งไปยังขบวนการตีความซึ่งอาศัยกฎเงื่อนไข(IF-Then Rule) ได้ค่าเชิงคลุมเครือออกมา นำไปผ่านขบวนการแปลงค่าให้เป็นเชิงตัวเลข ซึ่งเป็นค่าที่นำไปใช้งานต่อไป ขบวนการทางตรรกศาสตร์คลุมเครือเป็นดังรูปที่ 2 [3] เห็นได้ว่าคล้ายกับข่ายงานระบบประสาทในเชิงการประมาณค่าความสัมพันธ์ แต่ไม่ได้อาศัยหลักการเรียนรู้ แต่เป็นการอาศัยหลักการการสร้างสรรค์ความรู้ของมนุษย์ ดังนั้นข้อมูลและรูปแบบจะเป็นในเชิงการบรรยายแทน



รูปที่ 2 แสดงแบบโครงสร้างของตรรกศาสตร์แบบคลุมเครือ

ดังนั้นด้วยกลไกทางด้านเหตุผลและคุณสมบัติในการประมาณค่าทำให้ตรรกศาสตร์คลุมเครือมีมั่งคั่ง (Robustness) ในแต่ละตัวแปรต่างๆของระบบและต่อสิ่งรบกวน แต่กระนั้นก็ตามก็มีข้อเสียคือ ต้องใช้ผู้เชี่ยวชาญเฉพาะทางในการออกแบบระบบ ทำให้ต้องเสียเวลาในการออกแบบนาน

2.3 ระบบผสมระหว่างข่ายงานระบบประสาทและตรรกศาสตร์คลุมเครือ (Neuro-Fuzzy System Logic)

ในงานบทความนี้ได้นำระบบนิเวศที่ซึ่งสามารถเรียนรู้ด้วยตัวเองและสามารถจดจำรูปแบบความไม่เชิงเส้นของระบบพลวัตทางกลต่างๆได้ จากการศึกษาค้นคว้าผลงานที่ผ่านมาทำให้สามารถสรุปได้ว่าระบบนิเวศที่ซึ่งที่ควรออกแบบควรเริ่มจากระบบนิเวศ

ซึ่ง Takagi-Sugeno [1] ซึ่งสามารถสร้างระบบนี้จากข้อมูลทางตัวเลข (Numerical data) หรือจากข้อมูลเชิงบรรยาย (Knowledge base) ได้ ระบบนิเวศที่ซึ่งแบบ Takagi-Sugeno-Kang นั้น โดยพื้นฐานจะมีจำนวนกฎน้อย ก็สามารถบรรยายความซับซ้อนของระบบพลวัตที่ไม่เป็นเชิงเส้นได้ และน้อยกว่าระบบที่ซึ่งแบบ Mandani สำหรับระบบนิเวศที่ซึ่งแบบลำดับที่ 1 มีรูปแบบสมการสำหรับ K กฎ ดังต่อไปนี้

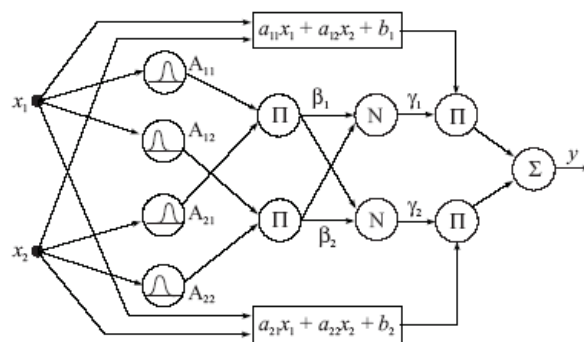
$$R_i : \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ and } \dots \text{ and } A_{in} \\ \text{then } y_i = a_i^T x + b_i, \quad i=1,2,\dots,K$$

เมื่อ R_i คือ กฎข้อที่ i x_1, x_2, \dots, x_n คือชุดข้อมูลขาเข้า (Input Variable) $A_{i1}, A_{i2}, \dots, A_{in}$ คือฟังก์ชันเซตที่เกี่ยวข้องกับข้อมูลขาเข้า y_i คือข้อมูลขาออก ซึ่งได้จากสมการเชิงเส้นในแต่ละกฎ และ a_i, b_i คือค่าคงที่ของส่วน consequent ในกฎของฟังก์ชัน ตัวอย่างเช่นระบบนิเวศที่ซึ่งที่มี ตัวแปร และ กฎ สมการที่ 1 จะเป็นดังนี้

$$R_1 : \text{If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{21} \\ \text{then } y_1 = a_{11}x_1 + a_{12}x_2 + b_1 \quad (2)$$

$$R_2 : \text{If } x_1 \text{ is } A_{21} \text{ and } x_2 \text{ is } A_{22} \\ \text{then } y_2 = a_{21}x_1 + a_{22}x_2 + b_2$$

และมีโครงสร้างข่ายงานดังรูปที่ 5



รูปที่ 3 แสดงตัวอย่างระบบนิเวศที่ซึ่งแบบ Takagi-Sugeno ลำดับที่ 1 สำหรับ 2 กฎ

และสมการขาออก ซึ่งหาโดยใช้การเฉลี่ยค่าน้ำหนักของแต่ละกฎ เป็นดังนี้



$$y = \frac{\sum_{i=1}^K \beta_i(\bar{x})y_i}{\sum_{i=1}^K \beta_i(x)} = \frac{\sum_{i=1}^K \beta_i(x)(a_i^T x + b_i)}{\sum_{i=1}^K \beta_i(x)} \quad (3)$$

$$= \sum_{i=1}^K \gamma_i(x)(a_i^T x + b_i)$$


เมื่อ $\beta_i(x)$ คือ Degree of fulfillment ของกฎข้อที่ i และ $\gamma_i(x)$ เป็นการนำ normalize ของ $\beta_i(x)$:ซึ่งเราเรียกค่านี้ว่า basis function expansion และในการเลือกสมการสมาชิก(Membership function) เราควรเลือก สมการที่มีความต่อเนื่อง (Continuous function) เพื่อสะดวกในการใช้กรรมวิธีทางคณิตศาสตร์เพื่อหาค่าที่เหมาะสม ในที่นี้เราเลือกสมการ Gaussian ซึ่งมีลักษณะสมการ ดังต่อไปนี้

$$u_{A_{ij}}(x_j, c_{ij}, \sigma_{ij}) = \exp\left(-\frac{(x_j - c_{ij})^2}{2\sigma_{ij}^2}\right) \quad (4)$$

เมื่อ ค่า c_{ij}, σ_{ij} ซึ่งเป็นค่าคงที่สำหรับสมการ Gaussian นั้น เราต้องทำการหาค่าและเมื่อเขียนในรูปของค่า degree of fulfillment จะได้ค่า γ_i^j ดังนี้

$$\gamma_i(\bar{x}) = \frac{\prod_{j=1}^p \exp\left(-\frac{(x_j - c_{ij})^2}{2\sigma_{ij}^2}\right)}{\sum_{i=1}^K \prod_{j=1}^p \exp\left(-\frac{(x_j - c_{ij})^2}{2\sigma_{ij}^2}\right)} \quad (5)$$

จากสมการข้างต้นที่ได้กล่าวมาแล้วนั้น ทำให้เราสามารถออกแบบส่วน Antecedent หรือส่วนหน้าของกฎเงื่อนไขให้มีส่วนทับกัน (Overlap) ทำให้ระบบนิเวศน์ของกฎข้อนี้เหมาะกับการประมาณค่าฟังก์ชัน ของระบบพลวัตได้ดี ดังรูปที่ 4 เห็นได้ว่าสามารถใช้ประมาณค่าสมการไม่เป็นเชิงเส้นได้เป็นอย่างดี



รูปที่ 4 แสดงการประมาณสมการไม่เป็นเชิงเส้น ของระบบนิเวศน์

ในการออกแบบระบบนิเวศน์แบบ Takagi-Sugeno ให้สามารถ สร้างตัวเองได้เองและสามารถปรับเปลี่ยนตัวไปตามข้อมูลขาเข้าและขาออก รวมถึงสามารถนำไปใช้แบบ online-learning เราสรุปขั้นตอนสำคัญได้ 3 ขั้นตอน ด้วยกันคือ

1. การสร้างกฎขึ้นมาอย่างอัตโนมัติในตอนเริ่มต้น (Initial Structure Identification)
2. การหาค่าพารามิเตอร์ของระบบในส่วน consequent ของแต่ละกฎ
3. การปรับโครงสร้างของระบบนิเวศน์ว่าควรเพิ่มหรือลดจำนวนกฎ

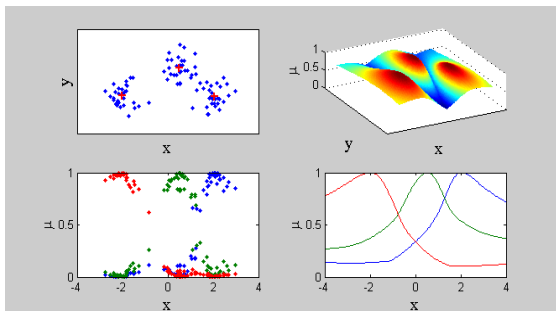
ในขบวนการที่ 1 และ 2 นั้นเป็นขบวนการที่เรียกว่า ขบวนการเรียนรู้ (Learning Process) ซึ่งกระทำทั้งสองรูปแบบก็คือ ใช้การเรียนรู้แบบมีผู้ช่วยสอน โดยใช้ข้อมูลทางคณิตศาสตร์ ซึ่งเป็นการเรียนรู้โดยใช้ข้อมูลในอดีต (Off-line training) และการเรียนรู้ที่อาศัยข้อมูลในปัจจุบัน ซึ่งเรียกว่าการเรียนรู้แบบทันที (Online training)

โดยในงานวิจัยนี้จึงมุ่งเน้นไปที่การประยุกต์ความรู้ของผู้เชี่ยวชาญและข้อมูลในอดีตที่สามารถหาได้ของระบบนั้นๆ มาทำการสร้างเป็นระบบนิเวศน์แบบอัตโนมัติ โดยการเลือกจำนวนข้อมูลขาเข้าและออกนั้นเป็นหน้าที่ของผู้เชี่ยวชาญ ส่วนการหาจำนวนฟังก์ชันสมาชิก (Membership function) ต่อข้อมูลขาเข้า และจำนวนกฎที่สอดคล้องกับข้อมูลขาเข้าแต่ละตัวนั้นจะถูกสร้างขึ้นมาเองโดยพิจารณาจากข้อมูลขาเข้าและออกของระบบที่เราสนใจ ขบวนการในการเลือกว่าแต่ละข้อมูลขาเข้ามีจำนวนฟังก์ชันสมาชิกกี่ตัวนั้น อาศัยหลักการแบ่งกลุ่มช่วงข้อมูลโดยใช้วิธีการ subtracting ซึ่งเป็นวิธีการใช้จำแนกกลุ่มข้อมูลที่รวดเร็วและแบ่งกลุ่มข้อมูลได้เองโดยไม่ต้องกำหนดจำนวนกลุ่มไว้ล่วงหน้า และที่ทำได้รวดเร็วเนื่องจากอาศัยการอ่านข้อมูลทั้งหมดเพียงครั้งเดียว

ตัวอย่างเช่น ถ้าแบ่งกลุ่มข้อมูลเป็นสามกลุ่ม สามารถเขียนส่วนฟังก์ชันสมาชิกของส่วนข้อมูลขาเข้า (Antecedent part) และตัวแปรต่างๆในส่วนหลังของกฎ (Consequent part) ของระบบนิเวศ Takagi-Sugeno ได้ดังนี้

$$\begin{aligned} \text{If } x \text{ is } A_1 \text{ then } y &= a_1x + b_1, \\ \text{If } x \text{ is } A_2 \text{ then } y &= a_2x + b_2, \\ \text{If } x \text{ is } A_3 \text{ then } y &= a_3x + b_3 \end{aligned} \quad (6)$$

โดยแต่ละกลุ่มจะแสดงหนึ่งกฎในระบบนิเวศ Takagi-Sugeno ค่าฟังก์ชันสมาชิกสำหรับเซต A_1 A_2 และเซต A_3 จะถูกสร้างโดยใช้สมการที่ 6 ข้างต้น และเป็นดังรูปที่ 5 ซึ่งแสดงให้เห็นถึงการแบ่งกลุ่มข้อมูลเป็นสามกลุ่ม จำนวนค่าสมาชิกฟังก์ชันแต่ละกลุ่ม ส่วนค่าตัวแปร a_i, b_i (Consequent parameter) สามารถปรับค่าให้ถูกต้องโดยใช้วิธีการประมาณค่าเหมาะสมเช่นวิธีประมาณค่าแบบ least square



รูปที่ 5 รูปแบบโครงสร้างของฟuzzy โดยใช้วิธีการแบ่งกลุ่ม โดยออกเป็นสามกลุ่ม

จากการออกแบบระบบนิเวศฟuzzy ดังที่กล่าวมานั้น สามารถนำระบบนี้ไปใช้ในหาแบบจำลองของระบบ ภายภาพหรือสร้างระบบควบคุมที่ซับซ้อนได้ ดังเช่นในงานวิจัยนี้ได้นำเสนอการประยุกต์ใช้กับทำนายค่าอุณหภูมิและค่าความชื้นสัมพัทธ์ล่วงหน้า ซึ่งจะได้กล่าวในหัวข้อต่อไป

3. ระเบียบวิธีวิจัย

สิ่งแรกที่ต้องคำนึงถึง คือแหล่งข้อมูล และการนำเข้าสู่ข้อมูล จากนั้นทำการวิเคราะห์ข้อมูลที่นำเข้ามา อย่างมีหลักการ เหตุผลว่ามีปัจจัยใด หรือปัจจัยใดสำคัญ และสำคัญอย่างไร จากนั้นทำการเตรียมข้อมูลเพื่อลดความ

ผิดพลาดของการเรียนรู้ เช่น การทำข้อมูลให้อยู่ในรูปแบบปกติ (Data Normalization) เพราะหากไม่มีการแปลงค่าให้อยู่ในรูปแบบปกติก่อนจะทำให้การถ่วงน้ำหนักของตัวแปรไม่เท่ากัน โดยกล่าวถึงต่อไป สุดท้ายเป็นวิธีการนำเข้าสู่ข้อมูลเหล่านั้นให้เหมาะสมกับกลวิธีทำงานระบบประสาท ระบบนิเวศฟuzzy แบบต่างๆ ที่นำมาประยุกต์ใช้นี้ เพื่อความถูกต้องของข้อมูลขาออกนำไปสู่ผลการพยากรณ์ที่แม่นยำยิ่งขึ้น

3.1 ข้อมูลและการนำเข้าสู่ข้อมูลที่เหมาะสมกับตัวแบบพยากรณ์อุณหภูมิ

การเก็บรวบรวมข้อมูลอุณหภูมิของประเทศไทย โดยเป็นข้อมูลย้อนหลังซึ่งบันทึกโดยเว็บไซต์ชื่อ <http://thai.wunderground.com/history/> ปรากฏข้อมูลดังรูปที่ 6 ซึ่งประกอบด้วยข้อมูลต่างๆดังนี้ อุณหภูมิสูงสุด อุณหภูมิเฉลี่ย อุณหภูมิต่ำสุด อุณหภูมิจุดน้ำค้าง ความชื้นสัมพัทธ์ ปริมาณน้ำฝน ระดับน้ำทะเล ความเร็วลม โดยในบทความนี้ ใช้ข้อมูลเป็นรายวัน และใช้เฉพาะข้อมูลเฉลี่ยเท่านั้น

History for Bangkok (Suvarnabhumi),

วันศุกร์, เมษายน 1, 2011 — View Current Conditions

วันศุกร์, เมษายน 1, 2011	
< Previous Day เมษายน 1 2011	
Daily Weekly Monthly Custom	
	Actual
Temperature	
Mean Temperature	28 เซลเซียส
Max Temperature	33 เซลเซียส
Min Temperature	24 เซลเซียส
Cooling Degree Days	18

รูปที่ 6 ตัวอย่างข้อมูลในเว็บไซต์ wunderground


จากรูปที่ 7 เป็นตัวอย่างข้อมูลอุณหภูมิของกรุงเทพมหานคร ในช่วงวันที่ 1 ธันวาคม 2554 จนถึง 31 มีนาคม 2555 โดยเส้นบนคือเส้นอุณหภูมิสูงสุดในแต่ละวัน เส้นตรงกลางคือเส้นอุณหภูมิเฉลี่ยของวันนั้น และเส้นล่างคือเส้นอุณหภูมิต่ำสุดของวันนั้น

เนื่องจากค่าของข้อมูลในแต่ละตัวแปรมีความแตกต่างกันมาก หากไม่มีการแปลงค่าให้อยู่ในรูปแบบปกติก่อนจะทำให้การถ่วงน้ำหนักของตัวแปรไม่เท่ากัน ดังนั้นจึงมีความจำเป็นต้องแปลงค่าให้ข้อมูลอยู่ในรูปแบบปกติก่อน โดยการใช้วิธี Min-Max Normalization ทำให้ข้อมูลอยู่ในช่วง -1 ถึง 1 ดังสมการที่ 7

$$x_{new} = \frac{(2 * x - (x_{max} + x_{min}))}{(x_{max} - x_{min})} \quad (7)$$

โดยที่

- x_{new} คือค่าหลังทำ Normalization
- x คือค่าก่อนทำ Normalization
- x_{max} คือค่าสูงสุดของชุดข้อมูลนั้น
- x_{min} คือค่าต่ำสุดของชุดข้อมูลนั้น



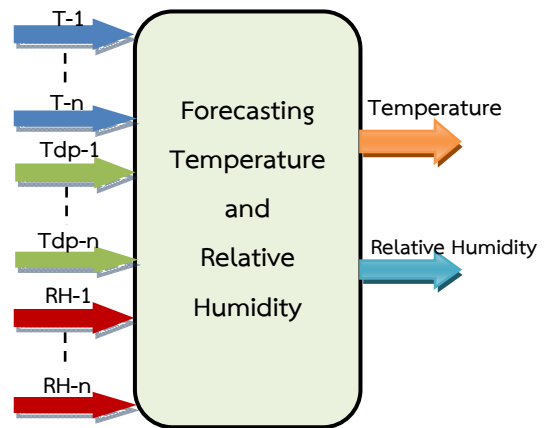
รูปที่ 7 ตัวอย่างข้อมูลอุณหภูมิที่ใช้ในการทำนายอุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้า

3.2 ตัวแบบพยากรณ์อุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้า

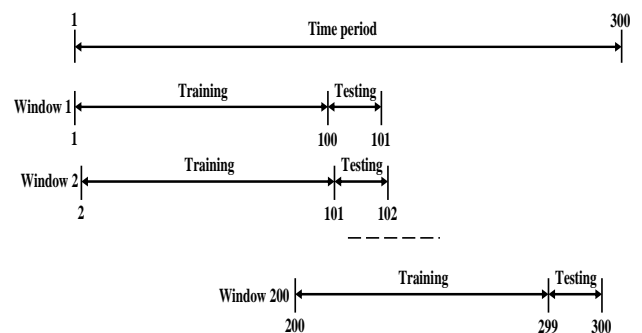
ในการออกแบบตัวแบบพยากรณ์อุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าข้อมูลขาออก(Output) คือค่าอุณหภูมิล่วงหน้า ส่วน ข้อมูลนำเข้า (Input) เพื่อใช้ในการทำนายข้อมูลในอนาคต นิยมใช้วิธีการอนุกรมเวลาซึ่งเป็นการนำเอาข้อมูลในอดีตที่ห่างกันในช่วงเวลาที่เท่าๆกันมาใช้สร้างเป็นข้อมูลนำเข้า ตัวอย่างเช่น ข้อมูลอนุกรมเวลาในช่วงเวลาที่ย้อนหลังไป n คาบเวลา ได้ชุดข้อมูลดังนี้ ข้อมูลขาเข้าได้แก่

- T-1 หมายถึงอุณหภูมิย้อนหลัง ณ เวลา 1 คาบเวลา
- T-2 หมายถึงอุณหภูมิย้อนหลัง ณ เวลา 2 คาบเวลา

- T-3 หมายถึงอุณหภูมิย้อนหลัง ณ เวลา 3 คาบเวลา
 - ⋮
 - T-n หมายถึงอุณหภูมิย้อนหลัง ณ เวลา n คาบเวลา
- และ
- Tdp-1 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 1 คาบเวลา
 - Tdp-2 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 2 คาบเวลา
 - Tdp-3 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 3 คาบเวลา
 - ⋮
 - Tdp-n คือ จุดน้ำค้างย้อนหลัง ณ เวลา n คาบเวลา
- และ
- RH-1 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 1 คาบเวลา
 - RH-2 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 2 คาบเวลา
 - RH-3 คือ จุดน้ำค้างย้อนหลัง ณ เวลา 3 คาบเวลา
 - ⋮
 - RH-n คือ จุดน้ำค้างย้อนหลัง ณ เวลา n คาบเวลา
- ดังนั้นระบบอัจฉริยะที่ใช้ในการทำนายค่าอุณหภูมิล่วงหน้าจึงมีลักษณะดังนี้



รูปที่ 8 ตัวแบบพยากรณ์อุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าด้วยระบบอัจฉริยะ



รูปที่ 9 ตัวแบบพยากรณ์อุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าด้วยระบบอัจฉริยะ



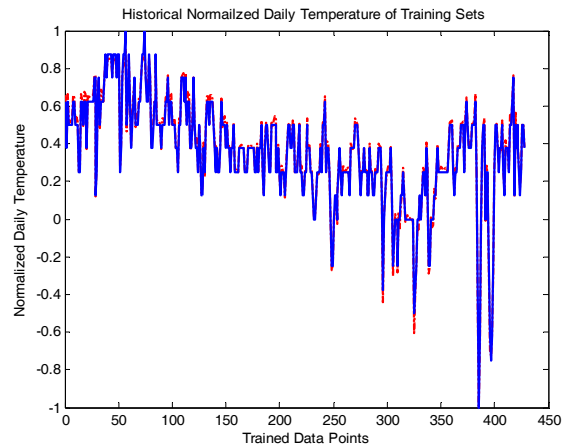
นอกจากนี้เพื่อให้การพยากรณ์ถูกต้อง สำหรับระบบอัจฉริยะแบบต่างๆ ต้องการชุดข้อมูลในอดีตที่ใกล้เคียงกับช่วงเวลาที่พยากรณ์เสนอ ดังนั้นข้อมูลในอดีตที่ใช้พยากรณ์อุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้าจึงต้องเคลื่อนที่ตลอดเวลา ดังรูปที่ 9 แสดงให้เห็นถึงการเคลื่อนที่ของชุดข้อมูล เช่นเมื่อต้องการทำนายข้อมูลที่ 101 ก็ใช้ข้อมูลในการสอนระบบอัจฉริยะตั้งแต่ข้อมูลชุดที่ 1 – 100 และเมื่อต้องการทำนายข้อมูลที่ 102 ก็ใช้ข้อมูลในการสอนระบบอัจฉริยะตั้งแต่ข้อมูลชุดที่ 2 – 101 เป็นต้น

4. ผลการทดลองและการวิจารณ์

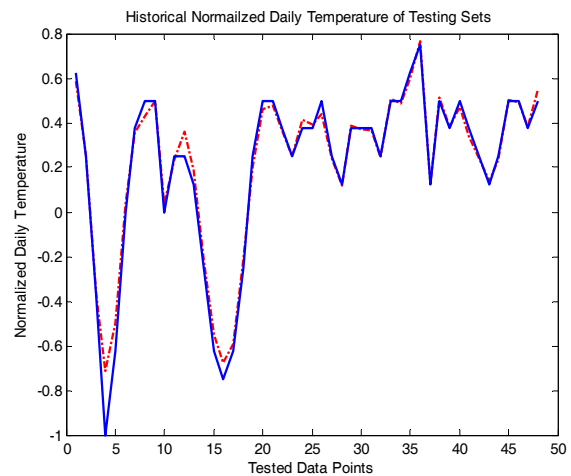
ในงานวิจัยนี้ศึกษาถึงการทำนายอุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้า 1 คาบเวลา ซึ่งในที่นี้ใช้ข้อมูลเป็นรายวัน ดังนั้นตัวแบบพยากรณ์ที่ได้จึงเป็นล่วงหน้า 1 วัน โดยใช้ชุดข้อมูลอุณหภูมิเฉลี่ย(Mean Temperature) จุดน้ำค้างเฉลี่ย (Mean Dew Point) ความชื้นสัมพัทธ์เฉลี่ย(Mean Relative Humidity)ของแต่ละวันของอุณหภูมิที่กรุงเทพมหานคร โดยเริ่มตั้งแต่ 1 มกราคม 2554 ถึง 30 เมษายน 2555 รวมเป็นข้อมูลทั้งหมด 486 ข้อมูล โดยทำการออกแบบระบบอัจฉริยะเป็นสามแบบ คือ แบบที่ 1 ใช้ข้อมูลย้อนหลัง 5 วัน(ข้อมูลขาเข้า 5 ข้อมูล, T-5,Tdp-5,RH-5) แบบที่ 2 ใช้ข้อมูลย้อนหลัง 10 วัน (ข้อมูลขาเข้า 10 ข้อมูล, T-10,Tdp-10,RH-10) และแบบที่ 3 ใช้ข้อมูลย้อนหลัง 20 วัน (ข้อมูลขาเข้า 20 ข้อมูล, T-20,Tdp-20,RH-20) นอกจากนี้ยังแบ่งชุดข้อมูลเป็น 2 ชุดข้อมูล โดยเป็นชุดข้อมูลที่ใช้สอน และใช้ทดสอบ โดยชุดข้อมูลที่ใช้ทดสอบเป็นข้อมูล 10 เปอร์เซนต์ของข้อมูลทั้งหมด เช่นข้อมูลทั้งหมด 486 ชุดข้อมูล แบ่งเป็นชุดที่ใช้สอน 438 ชุดข้อมูล และชุดข้อมูลที่ใช้ทดสอบ 48 ชุดข้อมูล

รูปที่ 10 เป็นผลที่ได้จากการสอนข่ายงานระบบประสาทแบบ Levenberg-Marquardt ที่มีปมประสาท 10 โหนด โดยเส้นทึบคืออุณหภูมิที่ใช้สอน และเส้นปะคือค่าอุณหภูมิที่ได้จากข่ายงานระบบประสาท ส่วนในรูปที่ 11 เป็นผลที่ได้จากการนำข่ายงานระบบประสาทไปใช้ใน

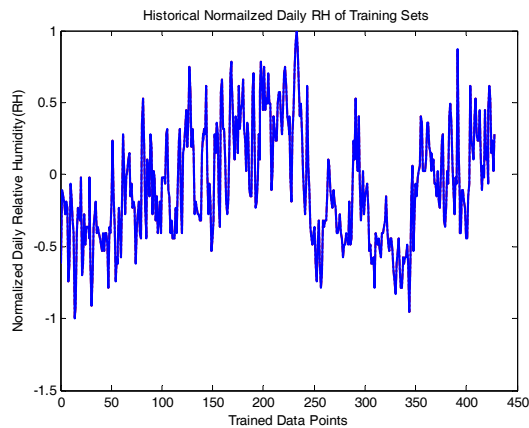
การทำนายอุณหภูมิและความชื้นสัมพัทธ์ล่วงหน้า พบว่าผลที่ได้จากข่ายงานระบบประสาท (เส้นปะ) ใกล้เคียงกับค่าอุณหภูมิจริง (เส้นทึบ)



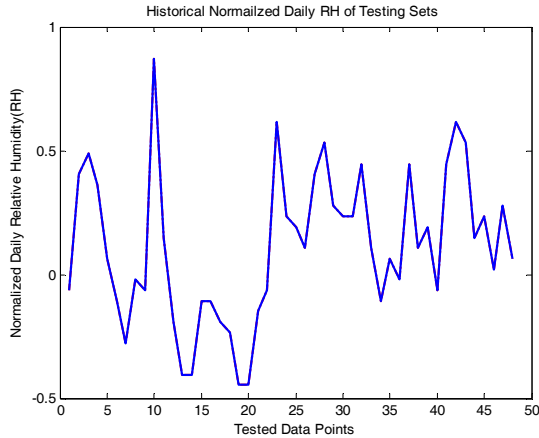
รูปที่ 10 ตัวแบบพยากรณ์อุณหภูมิล่วงหน้าด้วยระบบอัจฉริยะ ของชุดสอน



รูปที่ 11 ตัวแบบพยากรณ์อุณหภูมิล่วงหน้าด้วย NFs ของชุดทดสอบ



รูปที่ 12 ตัวแบบพยากรณ์ความชื้นสัมพัทธ์ล่วงหน้าด้วย NFs ของชุดสอน



รูปที่ 13 ตัวแบบพยากรณ์ความชื้นสัมพัทธ์ล่วงหน้าด้วย NFs ของชุดทดสอบ

ตารางที่ 1 ค่าความผิดพลาดของการสอน

Algorithm	Input	Output	Node	RMS		VAF	
				Train	Test	Train	Test
NN-LM	5	1	10	0.0618	1.5071	94.219	7.870
NN-SCG	5	1	10	0.1307	0.3362	75.890	40.893
ANFIS	5	1	3	0.1357	0.3752	74.015	17.957
NFs	5	1	20	0.1199	0.3474	79.737	19.569
NN-LM	10	1	10	0.0213	0.0570	99.500	97.518
NN-SCG	10	1	10	0.0308	0.1144	98.657	90.085
ANFIS	10	1	3	1.81e-7	2.01e-6	100.00	100.00
NFs	10	1	20	2.07e-16	3.19e-16	100.00	100.00
NN-LM	20	1	10	0.0318	1.2121	95.412	10.458
NN-SCG	20	1	10	0.1111	0.2331	80.123	50.458
ANFIS	20	1	3	0.1257	0.3542	78.123	18.123
NFs	20	1	20	5.12e-10	12.887	100.00	0.602

จากตารางที่ 1 เป็นชุดข้อมูลอุณหภูมิและความชื้นสัมพัทธ์ของกรุงเทพมหานคร แสดงให้เห็นถึงรูปแบบระบบอัจฉริยะทั้งสามแบบคือ T-5, T-10, T-20 พบว่าแบบที่ 2 ซึ่งใช้ข้อมูลย้อนหลัง 10 วัน ให้ผลค่าความผิดพลาดน้อยที่สุด โดยเฉพาะค่าความผิดพลาดของชุดทดสอบ (Test) ชำรงงานระบบประสาทให้ความถูกต้อง 97.518% ส่วนระบบนิโรฟซซี่ให้ค่าความถูกต้อง 100%

5. สรุปและข้อเสนอแนะ

การออกแบบตัวแบบพยากรณ์ค่าอุณหภูมิ ตัวแบบดังกล่าวเปรียบเทียบกับระหว่างชำนงานระบบประสาท ANFIS และระบบนิโรฟซซี่แบบ subtractive clustering ผลปรากฏว่าตัวแบบพยากรณ์ที่ใช้ระบบนิโรฟซซี่ (NFs) ให้ค่าความถูกต้องในการทำนายล่วงหน้า 1 ช่วงเวลา ดีที่สุดกว่าตัวแบบที่ใช้ระบบอัจฉริยะแบบอื่น ค่าได้ค่าความถูกต้องที่ 100 เปอร์เซ็นต์ จากผลการพยากรณ์ดังกล่าว สามารถประยุกต์ใช้ค่าอุณหภูมิ

ล่วงหน้าในการคำนวณภาระความร้อนในอาคาร เพื่อนำไปประหยัดพลังงานได้

6. เอกสารอ้างอิง

- [1] Takagi, T. and Sugeno, M., (1985). Fuzzy identification of systems and its application to modeling and control, *Proc. IEEE Transaction on SMC*, pp. 116-132.
- [2] Stinchcombe, H. K. M., (1989). Multi - Layer Feedforward Networks are universal Approximators, *Neural Network*, Vol. 2, , pp. 359 - 366.
- [3] Jang R, (1992). Neuro-Fuzzy Modeling: Architectures, Analyses and Applications, *PhD Thesis*, University of California, Berkeley.
- [4] Sala, C. H., Glahn, V. P., Bragulat, E. J., (2000). A statistical method to downscale temperature forecasts. A case study in Catalonia, *Meteorology Application*, Vol. 7, pp. 75-82.
- [5] Babuska, R.,(2002), Neuro-fuzzy methods for modeling and identification, in *Recent Advances in intelligent Paradigms and Application*, Springer-Verlag, pp. 161-186.
- [6] Song, K. B., Ha, S. K., Park, J. W., Kim, K. H., (2006). Hybrid Load Forecasting Method With Analysis of Temperature Sensitive, *IEEE Transactions on Power Systems*, Vol. 21, No. 2, May, pp. 869 – 876.
- [7] Hayati, M. and Mohebi, Z.,(2007). Temperature Forecasting Based on Neural Network Approach, *World Applied Sciences Journal*, Vol. 2, No. 6, pp. 613-620.
- [8] Baboo, S. S. and Shereef, I. K., (2010). An Efficient Weather Forecasting System Artificial Neural Network, *Int. Journal of Environmental Science and Development*, Vol. 1, No. 4., October, pp. 321 – 326.
- [9] Guo, Z. H., Wu, J., Lu, H. Y., Wang, J.Z., (2011), A case study on a hybrid wind speed forecasting method using BP neural network, *Knowledge-based systems*, Vol. 24, pp. 1048-1056.
- [10] Simon, S. K., Kwok, K. K., Eric W.M., (2011), An intelligent approach to assessing the effect of building occupancy on building cooling load prediction, *Building and Environment*, Vol. 46, pp. 1681-1690.