

วิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟสำหรับ พยากรณ์ปริมาณความเข้มข้นของฝุ่นละอองขนาด 2.5 ไมครอน Hybrid of Neural Network and Markov Chain Method for Predicting PM2.5 Concentrations

พรนภา แสงศรี* และพรพิมล ชัยวุฒิศักดิ์

ภาควิชาสถิติ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ถนนฉลองกรุง เขตลาดกระบัง กรุงเทพมหานคร 10520

Pornnapa Sangsri* and Pornpimol Chaiwuttisak

Department of Statistics, Faculty of Science, King Mongkut's Institute of Technology Ladkrabang,

Chalongkrung Road, Ladkrabang, Bangkok 10520

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบการพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน ด้วยวิธีโครงข่ายประสาทเทียม และวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟ โดยใช้ข้อมูลรายชั่วโมง ณ สถานีโรงไฟฟ้าพระนครใต้ ตำบลบางโพรง อำเภอเมือง จังหวัดสมุทรปราการ ตั้งแต่วันที่ 1 เดือนตุลาคม พ.ศ. 2563 ถึงวันที่ 11 เดือนพฤศจิกายน พ.ศ. 2563 รวมทั้งสิ้น 984 รายการ เป็นข้อมูลทุติยภูมิซึ่งเก็บรวบรวมโดยกรมควบคุมมลพิษ กระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อม งานวิจัยนี้ได้นำค่าพยากรณ์จากโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับมาแบ่งสถานะด้วยวิธีห่วงโซ่มาร์คอฟ เพื่อปรับค่าพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน ผลการศึกษาพบว่าราคาของค่าคลาดเคลื่อนกำลังสองเฉลี่ยและเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยด้วยวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟเท่ากับ 1.1890 และ 3.2972 ตามลำดับ ขณะที่ราคาของค่าคลาดเคลื่อนกำลังสองเฉลี่ยและเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยด้วยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเท่ากับ 2.4864 และ 7.2877 ตามลำดับ ซึ่งกล่าวได้ว่าการใช้วิธีผสมของโครงข่ายประสาทเทียมเพอร์เซพตรอนแบบหลายชั้นโดยมีการเรียนรู้แบบแพร่ย้อนกลับและห่วงโซ่มาร์คอฟให้ผลการพยากรณ์แม่นยำกว่าวิธีโครงข่ายประสาทเทียมเพอร์เซพตรอนแบบหลายชั้นโดยมีการเรียนรู้แบบแพร่ย้อนกลับ

คำสำคัญ : ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน; โครงข่ายประสาทเทียม; ตัวแบบห่วงโซ่มาร์คอฟ; การเรียนรู้แบบแพร่ย้อนกลับ; วิธีสมการเมทริกซ์

Abstract

The objective of the research was to study the prediction of particles less than 2.5 micrometers in diameter (PM_{2.5}) by using neural network and the hybrid of neural network and Markov chain model based on hourly data at the South Phra Nakhon Power Plant Station, Bang Prong sub-district, Muang district, Samut Prakan province from October 1, 2020, to November 11, 2020. A total of 984 observations were secondary data collected by the Pollution Control Department, Ministry of Natural Resources and Environment. In this research, prediction values from back-propagation neural network were classified by using Markov chain to adjust the prediction value of PM_{2.5} concentrations. The results showed that the root mean square error (RMSE) and mean absolute percent error (MAPE) of the hybrid of neural network and Markov chain model were 1.1890 and 3.2972, respectively. Simultaneously, the RMSE and MAPE using back-propagation neural network were equal to 2.4864 and 7.2877 respectively. It can be said that the hybrid of Markov chain and back-propagation in multilayer perceptron neural networks performs the higher forecasting accuracy than the back-propagation in multilayer perceptron neural networks.

Keywords: PM_{2.5}; neural network; Markov chain model; back-propagation neural network; matrix equation method

1. บทนำ

ปัจจุบันมลพิษในประเทศไทยเป็นปัญหาที่มีความสำคัญและทวีความรุนแรงมากขึ้น เนื่องมาจากวิถีการดำรงชีวิตที่เปลี่ยนแปลงไปและการเพิ่มขึ้นของจำนวนประชากรอย่างรวดเร็ว ทำให้ความต้องการทรัพยากรมีมากขึ้นด้วย รวมถึงการเติบโตด้านอุตสาหกรรม การคมนาคม เกษตรกรรม ซึ่งส่งผลให้ทรัพยากรธรรมชาติเสื่อมโทรมและลดลงไปอย่างรวดเร็ว ขณะเดียวกันก็ยังส่งผลทำให้เกิดมลพิษต่อสิ่งแวดล้อมเพิ่มมากยิ่งขึ้น ได้แก่ มลพิษทางอากาศ มลพิษทางน้ำ มลพิษทางเสียง มลพิษทางทัศนียภาพ เป็นต้น โดยมลพิษทางอากาศเป็นปัญหาสำคัญในปัจจุบันที่หลีกเลี่ยงได้ยากและมีภัยต่อสุขภาพ โดยสารมลพิษทางอากาศ เช่น ฝุ่นละอองขนาดเล็ก สารอันตรายประเภทต่าง ๆ ที่ปนเปื้อนอยู่ในชั้นบรรยากาศ

ค่าดัชนีคุณภาพอากาศ (air quality index, AQI) เป็นตัวเลขที่ใช้ประเมินสถานการณ์มลพิษทางอากาศในแต่ละพื้นที่ การวัดดัชนีคุณภาพอากาศได้จากการคำนวณปริมาณสารมลพิษทางอากาศ 5 ชนิด ได้แก่ ฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน (PM_{2.5}) ฝุ่นละอองขนาดไม่เกิน 10 ไมครอน (PM₁₀) ก๊าซโอโซน (O₃) ก๊าซคาร์บอนมอนอกไซด์ (CO) ก๊าซไนโตรเจนไดออกไซด์ (NO₂) และก๊าซซัลเฟอร์ไดออกไซด์ (SO₂) โดยเกณฑ์ดัชนีคุณภาพอากาศของประเทศไทยแบ่งเป็น 5 ระดับ คือ AQI 0-25 หมายถึงคุณภาพอากาศดีมาก AQI 26-50 หมายถึงคุณภาพอากาศดี AQI 51-100 หมายถึงคุณภาพอากาศปานกลาง AQI 101-200 หมายถึงคุณภาพอากาศเริ่มมีผลกระทบต่อสุขภาพ และ AQI \geq 201 หมายถึงคุณภาพอากาศมีผลกระทบต่อสุขภาพรุนแรง [1]

ปริมาณสารมลพิษทางอากาศที่มีอันตรายต่อสุขภาพมากที่สุดนั้น คือ ฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) เนื่องจากฝุ่นละออง PM2.5 มีขนาดเล็กมาก ไม่มีสี ไม่มีกลิ่น สามารถเข้าไปสู่ระบบทางเดินหายใจของมนุษย์โดยตรง สามารถทะลุเข้าสู่ถุงปอดทันที ดังนั้นฝุ่นละอองขนาดเล็กเหล่านี้จึงทำให้เกิดการระคายเคืองและมีผลต่อสุขภาพ โดยเฉพาะโรคทางเดินหายใจ สามารถทำลายอวัยวะของระบบทางเดินหายใจโดยตรง และยังทำให้เกิดการระคายเคืองตา ระคายคอ แสบหน้าอก หายใจถี่ หอบเหนื่อย เกิดอาการหอบหืด ภูมิแพ้ ไอพองได้ โดยปี พ.ศ. 2561 ในประเทศไทยมีหลายพื้นที่ที่มีปริมาณความเข้มข้นของ PM2.5 เฉลี่ยรายปีเกินมาตรฐานในบรรยากาศ ซึ่งกำหนดไว้ที่ 25 ไมโครกรัมต่อลูกบาศก์ ทั้งนี้มีการกำหนดค่าวัดคุณภาพของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 (PM2.5) ไว้ทั้งหมด 5 ระดับด้วยกัน [2]

การพยากรณ์ปริมาณความเข้มข้นของ PM2.5 สามารถนำมาเป็นข้อมูลประกอบการเฝ้าระวังคุณภาพอากาศที่จะเกิดขึ้นในอนาคต โดยมีงานวิจัยที่นำเสนอวิธีการพยากรณ์ เช่น กอแลมเรซ่า [3] ได้ใช้วิธีโครงข่ายประสาทเทียมและวิธีห้วงโซ่มาร์คอฟ โดยพิจารณาอุณหภูมิ โนโตรเจน ฝุ่นละอองขนาดเล็กไม่เกิน 10 ไมครอน และคาร์บอนมอนอกไซด์ เพื่อพยากรณ์ความเข้มข้นฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน พบว่าวิธีโครงข่ายประสาทเทียมให้ผลพยากรณ์ที่แม่นยำกว่าวิธีห้วงโซ่มาร์คอฟ กาญจนาน [4] ได้ใช้วิธีโครงข่ายเพอร์เซพตรอนแบบหลายชั้นโดยอาศัยการเรียนรู้แบบแพร่ย้อนกลับสำหรับพยากรณ์ปริมาณฝุ่นละอองขนาดเล็กไม่เกิน 10 ไมครอน (PM10) ซึ่งเป็นสารมลพิษทางอากาศที่เป็นปัญหาหลักในพื้นที่จังหวัดเชียงใหม่ โดยพบว่าจำนวนโหนดซ่อนมีผลต่อความถูกต้องในการพยากรณ์ในทางกลับกันทำให้ความเร็วในการวิเคราะห์ข้อมูลช้าลงไปมากเช่นกัน แต่เมื่อมีการเปลี่ยนแปลงค่า

โมเมนต์และอัตราการเรียนรู้ เพื่อทดสอบผลกระทบที่เกิดขึ้นโดยกำหนดค่าน้ำหนักเริ่มต้นที่ต่างกัน พบว่าความเร็วในการประมวลผลข้อมูลจะแปรผันตามค่าโมเมนต์และอัตราการเรียนรู้ที่เพิ่มขึ้นด้วย อาทากาน [5] ได้นำเสนอการพยากรณ์มลพิษทางอากาศ ณ อิสตันบูล ประเทศตุรกี ด้วยวิธีโครงข่ายประสาทเทียม โดยการพยากรณ์แบบ 1, 2 และ 3 วันล่วงหน้า พบว่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยของการทำนาย 3 วันล่วงหน้า มีค่าต่ำกว่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยของการทำนายแบบ 2 วันล่วงหน้า โดยความถูกต้องของตัวแบบการทำนายนั้นขึ้นอยู่กับจำนวนข้อมูลในระบบ การปรับเปลี่ยนจำนวนโหนดในชั้นนำเข้า ชั้นส่งออก และการกำหนดการเรียนรู้ของระบบ มูฮามัด [6] ได้กำหนดช่วงความรุนแรงของสารพิษทางอากาศ เพื่อหาความน่าจะเป็นความรุนแรงของสารพิษทางอากาศ นาเดียร์ [7] ได้นำเสนอการพยากรณ์คุณภาพอากาศ ณ เมืองมีรี ประเทศมาเลเซีย ด้วยวิธีห้วงโซ่มาร์คอฟ โดยแบ่งสถานะการทำนายเป็น 5 สถานะ คือ คุณภาพอากาศดี คุณภาพอากาศปกติ คุณภาพอากาศเริ่มมีปัญหาต่อสุขภาพ คุณภาพอากาศแย่ และคุณภาพอากาศอันตราย พบว่าความน่าจะเป็นของคุณภาพอากาศสามารถช่วยคาดการณ์อากาศในอนาคตได้ พบว่าโอกาสเกิดคุณภาพอากาศอันตรายในอนาคตจะสูงขึ้น (0.9737) มากกว่า 4 สถานะที่เหลือ

การศึกษาครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบการพยากรณ์ปริมาณความเข้มข้นของ PM2.5 รายชั่วโมง โดยวิธีโครงข่ายประสาทเทียม และวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟ ซึ่งพิจารณาจากรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error, RMSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (mean absolute percentage error, MAPE) ข้อมูลที่ใช้ในงานวิจัยนี้

เป็นข้อมูลที่วัดค่าได้ ณ สถานีโรงไฟฟ้าพระนครใต้ ตำบลบางโปรง อำเภอเมือง จังหวัดสมุทรปราการ ระหว่างวันที่ 1 เดือนตุลาคม พ.ศ. 2563 ถึงวันที่ 11 เดือนพฤศจิกายน พ.ศ. 2563 ทั้งนี้ผลที่ได้จากการศึกษาวิจัยสามารถนำไปใช้ในการวางแผนการควบคุมมลพิษเพื่อเป็นประโยชน์ต่อประชาชนในการดำรงชีวิตในอนาคต

2. วิธีดำเนินการวิจัย

การศึกษาเพื่อเปรียบเทียบการพยากรณ์ปริมาณความเข้มข้นของ PM2.5 รายชั่วโมง โดยวิธีโครงข่ายประสาทเทียม และวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟ ประกอบด้วยขั้นตอนการดำเนินงานดังรูปที่ 1 โดยอธิบายรายละเอียดในหัวข้อ 2.1-2.4

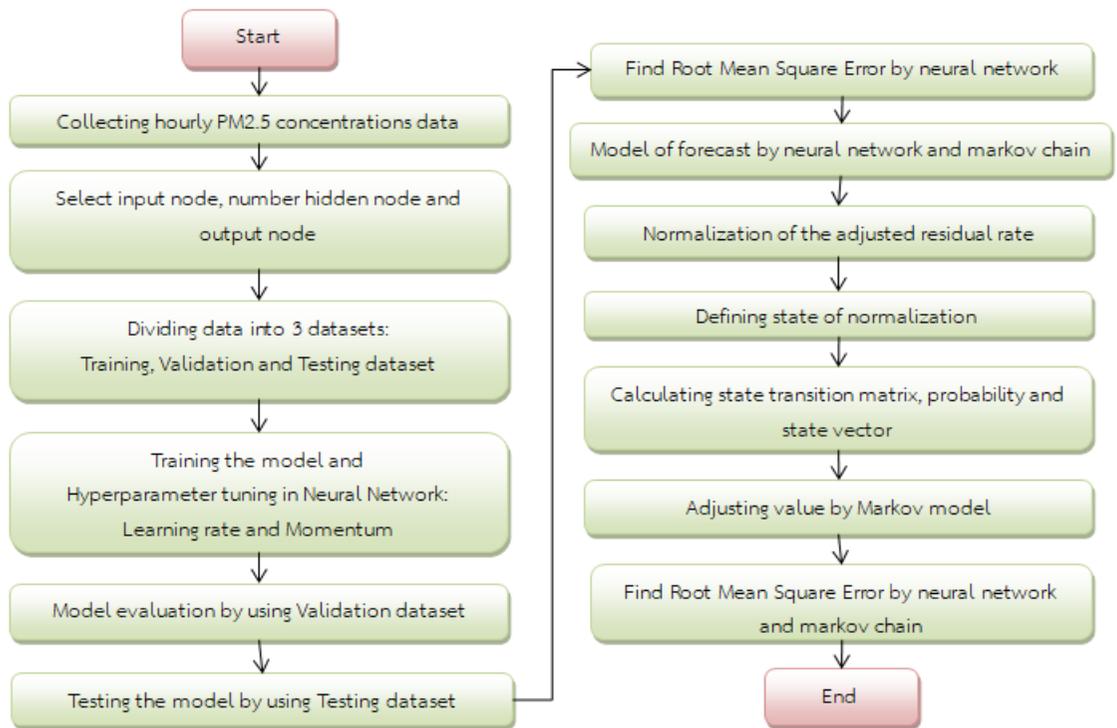


Figure 1 The framework of the research process for predicting hourly PM 2.5 concentrations

2.1 การรวบรวมข้อมูล

งานวิจัยนี้เริ่มต้นด้วยการนำข้อมูลปริมาณฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) รายชั่วโมง ณ สถานีโรงไฟฟ้าพระนครใต้ ตำบลบางโปรง อำเภอเมือง จังหวัดสมุทรปราการ ตั้งแต่วันที่ 1 เดือนตุลาคม พ.ศ. 2563 ถึงวันที่ 11 เดือนพฤศจิกายน พ.ศ. 2563 รวมทั้งสิ้น 984 รายการ โดยแบ่งข้อมูลเป็น 3 ส่วน ได้แก่ (1) ชุดฝึกสอน (training set) สำหรับสร้าง

ตัวแบบโครงข่ายประสาทเทียม ส่วนที่ 2 คือ ชุดตรวจสอบ (validation set) สำหรับตรวจสอบประสิทธิภาพของตัวแบบโครงข่ายประสาทเทียม และส่วนที่ 3 คือ ชุดทดสอบ (test set) สำหรับทดสอบความแม่นยำของตัวแบบโครงข่ายประสาทเทียม งานวิจัยนี้แบ่งข้อมูลโดยกำหนดร้อยละของสัดส่วนของจำนวนข้อมูลใน training set : validation set : test set เท่ากับ 70 : 20 : 10 [8]

2.2 การสร้างตัวแบบพยากรณ์โดยวิธี โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (artificial neural network) เป็นแบบจำลองทางคณิตศาสตร์ที่พยายามเลียนแบบกระบวนการทำงานของเซลล์ประสาทของมนุษย์ ซึ่งประกอบด้วยนิวรอน (neuron) หรือโหนด (node) ต่าง ๆ โดยแต่ละโหนดเชื่อมต่อกัน (interconnection) มีลักษณะคล้ายร่างแห และแต่ละเส้นการเชื่อมโยงจะมีค่าถ่วงน้ำหนัก (weight) ซึ่งสามารถปรับเปลี่ยนค่าสำหรับการเรียนรู้ที่เกิดขึ้น โดยโครงสร้างของโครงข่ายประสาทเทียมเพอร์เซพตรอนแบบหลายชั้น (multi-layer perceptron neural network, MLP neural network) มีชั้นโหนดนำเข้า (input layer) ชั้นโหนดส่งออก (output layer) และ

อย่างน้อยหนึ่งชั้นโหนดซ่อน (hidden layer) ดังรูปที่ 2 โครงข่ายประสาทเทียมเพอร์เซพตรอนแบบหลายชั้น โดยมีการเรียนรู้แบบแพร่ย้อนกลับ (back-propagation in MLP neural network) ซึ่งมีการนำข้อมูลอินพุตเข้าสู่โครงข่ายและเปรียบเทียบความคลาดเคลื่อนระหว่างค่าจริงและเอาต์พุตที่ได้จากการเรียนรู้ โดยเปลี่ยนแปลงค่าถ่วงน้ำหนักเพื่อให้ได้ผลลัพธ์ที่ใกล้เคียงกับค่าจริงมากที่สุด ซึ่งวิธีการเรียนรู้แบบแพร่ย้อนกลับมีพารามิเตอร์ที่ต้องพิจารณา คือ อัตราการเรียนรู้และค่าโมเมนตัม นอกจากนี้ฟังก์ชันกระตุ้น (activation function) ก็มีผลต่อประสิทธิภาพในการสร้างตัวแบบด้วยเช่นกัน [9] การวิเคราะห์ข้อมูลและสร้างตัวแบบโดยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับมีขั้นตอนการวิเคราะห์ดังต่อไปนี้

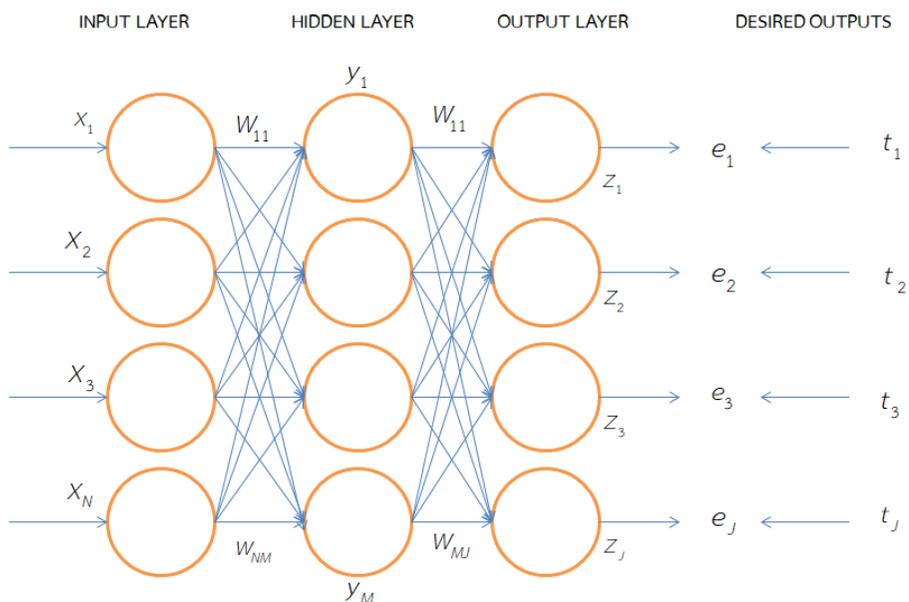


Figure 2 Multi-Layer Perceptron Neural Network

ขั้นตอนที่ 1 พิจารณาชั้นโหนดนำเข้า โดยการกำหนดตัวแปรนำเข้าสำหรับตัวแบบโครงข่ายประสาทเทียมที่เข้ากับข้อมูลอนุกรมเวลาต้องคำนึงเวลา

ย้อนหลัง (time lags) ในการเลือกช่วงเวลาย้อนหลังที่เหมาะสมจะพิจารณาโดยใช้ค่า autocorrelation (ACF) [10]

ขั้นตอนที่ 2 จัดเตรียมข้อมูลนำเข้า ในกรณีนี้ผู้วิจัยใช้ข้อมูลย้อนหลัง 5 ชั่วโมง สำหรับพยากรณ์ ณ ชั่วโมงที่ t ได้แก่ ข้อมูล ณ ชั่วโมงวันที่ $t-1, t-2, t-3, t-4$ และ $t-5$

ขั้นตอนที่ 3 นำข้อมูลมาแบ่งเป็น 3 ส่วน ได้แก่ (1) ชุดฝึกสอน จำนวน 685 รายการ (โดยคิดเป็นร้อยละ 70 ของข้อมูลทั้งหมด) (2) ชุดตรวจสอบ จำนวน 195 รายการ (โดยคิดเป็นร้อยละ 20 ของข้อมูลทั้งหมด) และ (3) ชุดทดสอบ จำนวน 99 รายการ (โดยคิดเป็นร้อยละ 10 ของข้อมูลทั้งหมด)

ขั้นตอนที่ 4 พิจารณาจำนวนโหนดซ่อน เนื่องจากยังไม่มีกฎเกณฑ์ที่แน่นอนในการกำหนดจำนวนโหนดซ่อน งานวิจัยที่ผ่านมานักวิจัยมักกำหนดจำนวนโหนดซ่อนโดยทดลองปรับเปลี่ยนจำนวนโหนดไปเรื่อย ๆ จนกระทั่งได้จำนวนโหนดที่เหมาะสม [11] ซึ่งได้กำหนดจำนวนโหนดซ่อนที่เหมาะสม ดังสมการที่ (1)

$$N_{hidden} \leq \frac{N_{train} E_{tolerance}}{N_{pts} + N_{output}} \quad (1)$$

โดยที่ N_{hidden} คือ จำนวนโหนดซ่อน; N_{train} คือ ชุดข้อมูลนำเข้า; $E_{tolerance}$ คือ อัตราความคลาดเคลื่อน; N_{pts} คือ จำนวนโหนดชั้นนำเข้า; N_{output} คือ จำนวนโหนดชั้นส่งออก

ขั้นตอนที่ 5 กำหนดค่าพารามิเตอร์ของอัตราการเรียนรู้ (learning rate, η) ค่าโมเมนตัม (momentum, α) จำนวนรอบการเรียนรู้

ขั้นตอนที่ 6 รับค่าข้อมูลนำเข้าในชุดแรก เพื่อใช้ในการคำนวณหาค่าในชั้นส่งออก โดยใช้ข้อมูลชุดฝึกสอน

ขั้นตอนที่ 7 คำนวณค่าผลรวมของโหนดชั้นซ่อน (S_m) ก่อนปรับค่ารวมด้วยฟังก์ชันกระตุ้น (activation function) ได้แก่ ฟังก์ชันซิกมอยด์ ซึ่งจะ

ได้ค่าของโหนดในชั้นซ่อนที่อยู่ในช่วง $[0,1]$ โดยมีรายละเอียดดังสมการที่ (2)-(4)

ค่าเอาต์พุตของชั้นซ่อนก่อนปรับค่า ดังสมการที่ (2)

$$S_m = \sum_{n=1}^N X_n W_{nm} \quad (2)$$

เมื่อ S_m คือ เอาต์พุตชั้นซ่อน ก่อนปรับค่า (activation) เป็น y_m ; X_n คือ อินพุตโหนดที่ n จากทั้งหมด N โหนด; W_{nm} คือ น้ำหนักของเส้นเชื่อมระหว่างชั้นนำเข้ากับชั้นซ่อน

ค่าเอาต์พุตของชั้นซ่อนหลังปรับค่า ดังสมการที่ (3)

$$y_m = f(S_m) \quad (3)$$

เมื่อ y_m คือ เอาต์พุตของชั้นซ่อน หลังปรับค่าของโหนดที่ m จากทั้งหมด M โหนด

ฟังก์ชันที่ใช้ปรับค่า $f(x)$ ดังสมการที่ (4)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

คำนวณค่าเอาต์พุตของโหนดในชั้นส่งออก ด้วยสมการที่ (5) จากนั้นปรับค่าผลรวมด้วยฟังก์ชันกระตุ้น ได้แก่ ฟังก์ชันซิกมอยด์ ดังสมการที่ (4) ซึ่งจะได้ค่าของโหนดในชั้นส่งออกที่อยู่ในช่วง $[0,1]$ สำหรับค่าของผลลัพธ์ในโหนดของชั้นส่งออกนั้นหลังปรับค่าแสดง ดังสมการที่ (6)

$$V_j = \sum_{m=1}^M y_m W_{mj} \quad (5)$$

เมื่อ V_j คือ เอาต์พุตของชั้นส่งออกก่อนปรับค่า (activation) เป็น Z_j ; W_{mj} คือ น้ำหนักของเส้นเชื่อมระหว่างชั้นซ่อนกับชั้นส่งออก; y_m คือ เอาต์พุตของชั้นซ่อน หลังปรับค่าของโหนดที่ m จากทั้งหมด M โหนด

ค่าเอาต์พุตของชั้นส่งออกหลังการปรับค่า ดังสมการที่ (6)

$$Z_j = f(V_j) \quad (6)$$

เมื่อ Z_j คือ ค่าเอาต์พุตที่ได้ปรับค่าแล้วในชั้นเอาต์พุต โหนดที่ j จากทั้งหมด J โหนด

การหาค่าความคลาดเคลื่อนของโหนดในชั้นส่งออกและปรับค่าถ่วงน้ำหนัก โดยการนำเอาต์พุตที่คำนวณได้จริงเปรียบเทียบกับเอาต์พุตที่กำหนดไว้เพื่อหาค่าความคลาดเคลื่อนของข้อมูล โดยถ้าค่าผิดพลาดของข้อมูลน้อยกว่าข้อผิดพลาดที่ยอมรับได้แล้วนั้น โครงข่ายประสาทเทียมก็จะรับข้อมูลชุดต่อไปเข้าสู่โครงข่าย โดยถ้าไม่ได้ปรับค่าถ่วงน้ำหนักแล้วนั้น โครงข่ายประสาทเทียมจะรับข้อมูลแฉกถัดไป แล้วกลับไปทำในสมการ (2)-(4)

ค่าความคลาดเคลื่อนในแต่ละแถวของข้อมูลดังสมการที่ (7)

$$e^{(q)} = \frac{1}{2} \sum_{j=1}^J (t_j - z_j)^2 \quad (7)$$

เมื่อ $e^{(q)}$ คือ ค่าผิดพลาดของข้อมูลตัวอย่าง; t_j คือ ค่าเอาต์พุตที่ต้องการที่ชั้นส่งออกโหนดที่ j จากทั้งหมด J โหนด

การปรับน้ำหนักระหว่างโหนดในชั้นซ่อนและชั้นนำออก ดังสมการที่ (8)

$$W_{mj}^{(r+1)} = W_{mj}^{(r)} + \eta \{ (t_j^{(q)} - z_j^{(q)}) [z_j^{(q)} (1 - z_j^{(q)})] y_j^{(q)} \} \quad (8)$$

เมื่อ η คือ อัตราการเรียนรู้มีค่าอยู่ระหว่าง 0 ถึง 1; r คือ จำนวนรอบที่จะเรียนรู้ มี R เป็นจำนวนรอบที่กำหนด; q คือ จำนวนชุดของข้อมูลตัวอย่าง มี Q เป็นตัวกำหนด

การปรับน้ำหนักระหว่างโหนดในชั้นนำเข้าและชั้นซ่อน ดังสมการที่ (9)

$$W_{nm}^{(j+1)} = W_{nm}^{(j)} + \eta \left\{ \sum_{j=1}^J (t_j^{(q)} - z_j^{(q)}) [z_j^{(q)} (1 - z_j^{(q)})] W_{mj}^{(j)} \right\} * [y_m^{(q)} (1 - y_m^{(q)})] [X_n^{(q)}] \quad (9)$$

ขั้นตอนที่ 8 คำนวณ RMSE ด้วยข้อมูลชุดฝึกสอน แสดงดังสมการที่ (10)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (10)$$

เมื่อ Y_t คือ ค่าสังเกตของอนุกรมเวลา t ; n คือ ขนาดของอนุกรมเวลา; e_t คือ ค่าความคลาดเคลื่อนของอนุกรมเวลา t ซึ่ง $e_t = Y_t - \hat{Y}_t$

ขั้นตอนที่ 9 ตรวจสอบความถูกต้องของโครงข่ายประสาทเทียม โดยนำค่าถ่วงน้ำหนักที่ได้จากการฝึกโครงข่ายมาใช้ในการตรวจสอบความถูกต้องด้วยข้อมูลชุดตรวจสอบ แล้วเปรียบเทียบ RMSE ที่ได้จากข้อมูลชุดฝึกสอนและข้อมูลชุดตรวจสอบ หากมีค่าแตกต่างกันมากจะปรับค่าน้ำหนักใหม่และออกแบบโครงข่ายประสาทเทียมใหม่

ขั้นตอนที่ 10 พยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ได้จากขั้นตอนที่ 9 และเปรียบเทียบกับค่าจริงในข้อมูลชุดทดสอบ พร้อมทั้งคำนวณ RMSE ด้วยสมการที่ (10)

2.3 การสร้างตัวแบบพยากรณ์โดยวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟ

การสร้างตัวแบบโครงข่ายประสาทเทียมด้วยการปรับปรุงโดยห่วงโซ่มาร์คอฟ มีขั้นตอนดังนี้

ขั้นตอนที่ 1 คำนวณอัตราความคลาดเคลื่อนในการพยากรณ์ด้วยวิธีโครงข่ายประสาทเทียม ดังสมการที่ (11)

$$y_i = \frac{x_{ia} - x_{ip}}{x_{ia}} \times 100 \quad (11)$$

เมื่อ y_i คือ อัตราความคลาดเคลื่อนในการพยากรณ์วันที่ i ; x_a คือ ค่าปริมาณฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) วันที่ i ; x_p คือ ค่าพยากรณ์ของปริมาณฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) วันที่ i

ขั้นตอนที่ 2 หลังจากคำนวณอัตราความคลาดเคลื่อนในการพยากรณ์แล้ว จะลดขนาดของช่วงข้อมูลต่างกัน โดยการจัดค่าของข้อมูลให้อยู่ในช่วงเดียวกัน โดยการทำให้ normalization ตามสมการที่ (12) ซึ่งผลลัพธ์จะมีค่าอยู่ในช่วง $[0,1]$

$$Normalization = \frac{y_i - \min}{\max - \min} \quad (12)$$

เมื่อ y_i คือ อัตราส่วนความคลาดเคลื่อนในการพยากรณ์; min คือ ค่าที่น้อยที่สุดของอัตราส่วนความคลาดเคลื่อนในการพยากรณ์; max คือ ค่าที่มากที่สุดของอัตราส่วนความคลาดเคลื่อนในการพยากรณ์

ขั้นตอนที่ 3 นำข้อมูลที่ได้จากขั้นตอนที่ 2 มาวิเคราะห์โดยห้วงโซ่มาร์คอฟ พร้อมทั้งกำหนดสถานะปัจจุบันของระบบ เนื่องจากสถานะในอนาคตของระบบจะไม่ขึ้นกับสถานะในอดีต แต่จะขึ้นอยู่กับสถานะปัจจุบันเท่านั้น โดยงานวิจัยนี้แบ่งสถานะเป็น 5 สถานะ [12] ซึ่งสามารถคำนวณหาช่วงของ normalization ในแต่ละสถานะ ดังนี้ $(-\infty, \bar{x} - \alpha_1 S)$, $(\bar{x} - \alpha_1 S, \bar{x} - \alpha_2 S)$, $(\bar{x} - \alpha_2 S, \bar{x} + \alpha_3 S)$, $(\bar{x} + \alpha_3 S, \bar{x} + \alpha_4 S)$, $(\bar{x} + \alpha_4 S, +\infty)$ และ \bar{x} คือ ค่าเฉลี่ยของ normalization และ S คือ ส่วน

$$P = \begin{bmatrix} p_{11} / p_1 & p_{12} / p_1 & p_{13} / p_1 & p_{14} / p_1 & p_{15} / p_1 \\ p_{21} / p_2 & p_{22} / p_2 & p_{23} / p_2 & p_{24} / p_2 & p_{25} / p_2 \\ p_{31} / p_3 & p_{32} / p_3 & p_{33} / p_3 & p_{34} / p_3 & p_{35} / p_3 \\ p_{41} / p_4 & p_{42} / p_4 & p_{43} / p_4 & p_{44} / p_4 & p_{45} / p_4 \\ p_{51} / p_5 & p_{52} / p_5 & p_{53} / p_5 & p_{54} / p_5 & p_{55} / p_5 \end{bmatrix} \quad (13)$$

ขั้นตอนที่ 5 หาเวกเตอร์ความน่าจะเป็นของการทำนาย ณ ช่วงเวลาที่ n โดยคำนวณจากเมทริกซ์ความน่าจะเป็นการเปลี่ยนแปลงสถานะ ได้ดังเวกเตอร์ที่ (14)

$$P(n) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \end{bmatrix} P^n \quad (14)$$

เมื่อกำหนดให้ $\begin{bmatrix} 1 & 0 & 0 & 0 & 0 \end{bmatrix}$ เป็นเมทริกซ์ความน่าจะเป็นที่ระบบเปลี่ยนแปลงในสถานะต่าง ๆ

ขั้นตอนที่ 6 คำนวณค่าพยากรณ์โดยการหาค่าเฉลี่ยของช่วงการทำนายของห้วงโซ่มาร์คอฟ

เบี่ยงเบนมาตรฐานของ normalization โดยความถี่ของการเปลี่ยนแปลงสถานะแสดงดังตารางที่ 1

Table 1 Markov state transition

State	(1)	(2)	(3)	(4)	(5)
(1)	p_{11}	p_{12}	p_{13}	p_{14}	p_{15}
(2)	p_{21}	p_{22}	p_{23}	p_{24}	p_{25}
(3)	p_{31}	p_{32}	p_{33}	p_{34}	p_{35}
(4)	p_{41}	p_{42}	p_{43}	p_{44}	p_{45}
(5)	p_{51}	p_{52}	p_{53}	p_{54}	p_{55}

ขั้นตอนที่ 4 ตารางที่ 1 สามารถหาเมทริกซ์ความน่าจะเป็นการเปลี่ยนแปลงสถานะ (state transition probability matrix) โดย p_1, p_2, p_3, p_4 และ p_5 เป็นความถี่สะสมของสถานะปัจจุบันที่ 1, 2, 3, 4 และ 5 แสดงดังเมทริกซ์ที่ (13)

(Markov prediction interval) ที่มีความน่าจะเป็นสูงสุดในช่วงเวลาที่ n

2.4 การเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์

การวิจัยครั้งนี้ใช้เกณฑ์ในการเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์จาก RMSE ดังสมการที่ (10) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ดังสมการที่ (15) โดยพิจารณา RMSE และ MAPE ที่มีค่าต่ำสุด

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{e_t}{Y_t} \right| \tag{15}$$

เมื่อ Y_t คือ ค่าสังเกตของอนุกรมเวลา t ; n คือ ขนาดของอนุกรมเวลา; e_t คือ ค่าความคลาดเคลื่อนของอนุกรมเวลา t ซึ่ง $e_t = Y_t - \hat{Y}_t$

3. ผลการวิจัย

3.1 ผลการพยากรณ์โดยวิธีโครงข่ายประสาทเทียม

รูปที่ 3 แสดงการเปรียบเทียบค่า RMSE ของตัวแบบพยากรณ์โดยวิธีโครงข่ายประสาทเทียมซึ่งกำหนดค่าอัตราการเรียนรู้ และค่าโมเมนตัมที่ต่างกัน เพื่อนำมาใช้ในการกำหนดค่าพารามิเตอร์สำหรับสร้างตัวแบบพยากรณ์โดยวิธีโครงข่ายประสาทเทียม

ตารางที่ 2 แสดงตัวแบบโครงข่ายประสาทเทียมที่เหมาะสม โดยกำหนดให้จำนวนโหนดชั้นนำเข้าเท่ากับ 5 โหนด จำนวนโหนดชั้นซ่อนเท่ากับ 6 โหนด

และจำนวนโหนดชั้นส่งออกเท่ากับ 1 โหนด รวมทั้งค่าอัตราการเรียนรู้ (learning rate) เท่ากับ 0.05 โมเมนตัม (momentum) เท่ากับ 0.6 และจำนวนรอบในการเรียนรู้ (iteration) เท่ากับ 10,000 รอบ โดยค่า RMSE ของตัวแบบพยากรณ์ในระหว่างการฝึกสอนเท่ากับ 2.5610 ขณะที่ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยโดยใช้ข้อมูลชุดทดสอบเท่ากับ 2.4864

3.2 ผลการพยากรณ์โดยวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟ

การสร้างตัวแบบโครงข่ายประสาทเทียมปรับปรุงด้วยห่วงโซ่มาร์คอฟจะคำนวณหาอัตราความคลาดเคลื่อนในการพยากรณ์ด้วยสมการที่ (11) แล้วจึง normalization โดยค่าที่ได้จะอยู่ในช่วง [0,1] ซึ่งสามารถคำนวณจากสมการที่ (12) และในตารางที่ 4 แสดง normalization ของความคลาดเคลื่อนของการพยากรณ์รายชั่วโมง

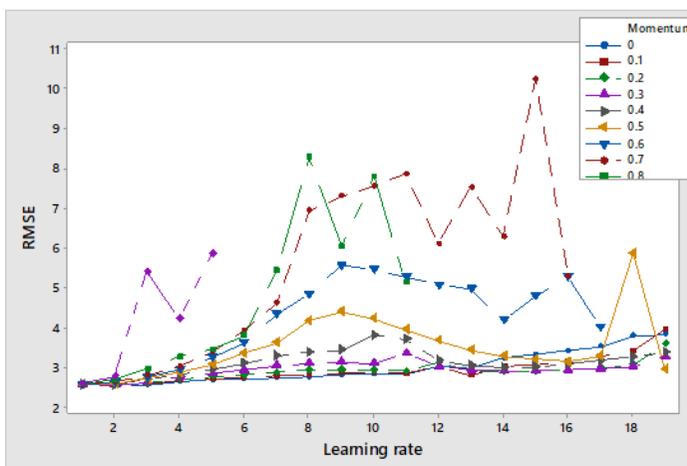


Figure 3 A comparison of RMSE among different learning rates and momentums

Table 2 Neural network model.

Model	Learning rate	Momentum	Iteration	RMSE
5-6-1	0.05	0.6	10,000	2.5610

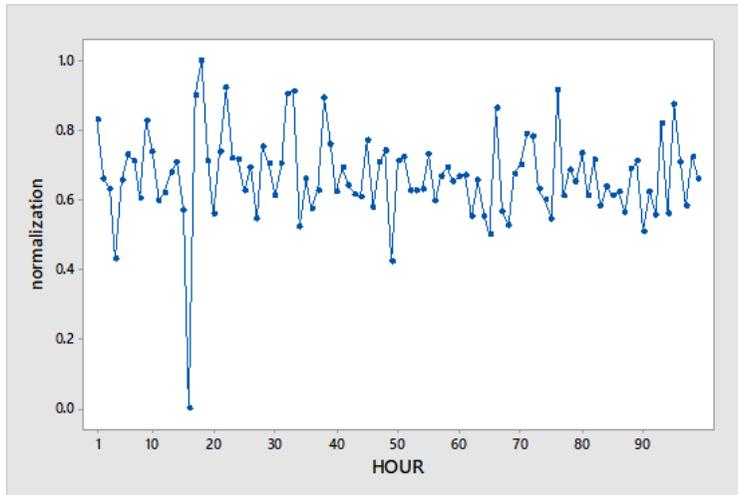


Figure 4 Forecast errors

ข้อมูลที่ปรับให้อยู่ในรูปแบบของ normalization ข้างต้น สามารถแบ่งเป็นช่วงของแต่ละสถานะ เป็น $[0,0.206]$, $(0.206,0.402]$, $(0.402,0.598]$, $(0.598,0.794]$, $(0.794,1]$ ซึ่งแสดงจำนวนการเปลี่ยนแปลงสถานะได้ดังตารางที่ 3

Table 3 Markov state transition

States	(1)	(2)	(3)	(4)	(5)	Total
(1)	0	0	0	0	1	1
(2)	0	0	0	0	0	0
(3)	1	0	2	14	4	21
(4)	0	0	16	44	4	64
(5)	0	0	3	7	2	12
Total	1	0	21	65	11	98

ตารางที่ 3 แสดงจำนวนครั้งของการเปลี่ยนสถานะจากสถานะหนึ่งไปยังอีกสถานะหนึ่ง โดยพบว่าการเปลี่ยนจากสถานะ (1) ไปยังสถานะ (2), (3), (4) มีการเปลี่ยนแปลงสถานะ 0 ครั้ง จากสถานะ (1) ไปยังสถานะ (5) มีการเปลี่ยนแปลงสถานะ 1 ครั้ง โดย

คำนวณความน่าจะเป็นได้ดังสมการที่ (13) ซึ่งสามารถคำนวณความน่าจะเป็นของการเปลี่ยนแปลงสถานะตำแหน่งที่ n ไปยังตำแหน่งที่ m และสามารถแสดงในเมทริกซ์ความน่าจะเป็นได้ดังเมทริกซ์ที่ (16) ดังนี้

$$\begin{aligned}
 p_{11} &= \frac{0}{1} = 0 & p_{12} &= \frac{0}{1} = 0 & p_{13} &= \frac{0}{1} = 0 \\
 p_{14} &= \frac{0}{1} = 0 & p_{15} &= \frac{1}{1} = 1 & p_{21} &= \frac{0}{0} = 0 \\
 p_{22} &= \frac{0}{0} = 0 & p_{23} &= \frac{0}{0} = 0 & p_{24} &= \frac{0}{0} = 0 \\
 p_{25} &= \frac{0}{0} = 0 & p_{31} &= \frac{1}{21} = 0.0476 & p_{32} &= \frac{0}{21} = 0 \\
 p_{33} &= \frac{2}{21} = 0.0952 & p_{34} &= \frac{14}{21} = 0.6667 & p_{35} &= \frac{4}{21} = 0.1905 \\
 p_{41} &= \frac{0}{64} = 0 & p_{42} &= \frac{0}{64} = 0 & p_{43} &= \frac{16}{64} = 0.25 \\
 p_{44} &= \frac{44}{64} = 0.6875 & p_{45} &= \frac{4}{64} = 0.0625 & p_{51} &= \frac{0}{12} = 0 \\
 p_{52} &= \frac{0}{12} = 0 & p_{53} &= \frac{3}{12} = 0.25 & p_{54} &= \frac{7}{12} = 0.5833 \\
 p_{55} &= \frac{2}{12} = 0.1667
 \end{aligned}$$

$$p = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0.0476 & 0 & 0.0952 & 0.6667 & 0.1905 \\ 0 & 0 & 0.25 & 0.6875 & 0.0625 \\ 0 & 0 & 0.25 & 0.5833 & 0.1667 \end{bmatrix} \quad (16)$$

เมทริกซ์ความน่าจะเป็นที่ (16) สามารถหาเวกเตอร์ความน่าจะเป็นของการทำนาย ซึ่งสามารถคำนวณจากสมการที่ (14) แสดงดังตารางที่ 4

ตารางที่ 5 กำหนดให้ (1) แทนปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน ที่เกิดขึ้นในแต่ละชั่วโมง (hourly PM2.5 concentrations value) (2) แทนค่าพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน

2.5 ไมครอน รายชั่วโมง (prediction hourly PM2.5 concentrations value) โดยวิธีโครงข่ายประสาทเทียม (3) แทนช่วงการทำนายสถานะห้วงโซ่มาร์คอฟ (Markov prediction interval) (4) แทนเวกเตอร์ความน่าจะเป็นของการทำนาย (probability) (5) แทนการปรับค่าการพยากรณ์ด้วยห้วงโซ่มาร์คอฟ (adjustment value) โดยกำหนดเวกเตอร์ความน่าจะเป็นของการทำนาย (4) จากความน่าจะเป็นสูงสุดของแต่ละเวกเตอร์ที่ n ซึ่งแสดงดังตารางที่ 4 และใช้เลือกค่าเฉลี่ยช่วงการทำนายสถานะห้วงโซ่มาร์คอฟใน (3) สำหรับการปรับการพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน รายชั่วโมง (5) ด้วยห้วงโซ่มาร์คอฟ โดยตารางที่ 5 แสดงตัวอย่างการพยากรณ์ 1

Table 4 Probability of n-step state vector

States	Step 1	Step 2	Step 3	Step 4	Step 5	...	Step 97	Step 98	Step 99
(1)	0.00	0.00	0.01	0.01	0.01	...	0.01	0.01	0.01
(2)	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.00
(3)	0.00	0.25	0.21	0.21	0.21	...	0.21	0.21	0.21
(4)	0.00	0.58	0.66	0.66	0.66	...	0.66	0.66	0.66
(5)	1.00	0.17	0.11	0.11	0.11	...	0.11	0.11	0.11

Table 5 Forecast one hour in advance

Hour	(1)	(2)	(3)	(4)	(5)	Error of prediction		RMSE		MAPE		
						B-PNN	B-PNN & MC	B-PNN	B-PNN & MC	B-PNN	B-PNN & MC	
1	22	18.813	[18.153	19.054]	0.00	22.209	14.486 %	-0.951 %	3.187	0.2093	0.1449	0.0095
			[19.054	19.956]	0.00							
			[19.956	20.857]	0.00							
			[20.857	21.758]	0.00							
			[21.758	22.660]	1.00							
						Total	2.4864	1.1890	7.2877	3.2972		

ชั่วโมงล่วงหน้า พบว่าค่าพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน รายชั่วโมง โดยวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟ (5) ใกล้เคียงกับค่าจริง (1) มากกว่าค่าพยากรณ์ปริมาณฝุ่นละอองขนาดไม่เกิน 2.5 ไมครอน รายชั่วโมง โดยวิธีโครงข่ายประสาทเทียม (2) นอกจากนี้ผลการพยากรณ์ด้วยข้อมูลชุดทดสอบพบว่า RMSE และ MAPE โดยวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟเท่ากับ 1.1890 และ 3.2972 ตามลำดับ

3.3 ผลการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมและวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟ

รูปที่ 5 แสดงค่าจริงแทนด้วยเส้นทึบสีฟ้า (-) ค่าพยากรณ์โดยวิธีโครงข่ายประสาทเทียมแทนด้วยเส้นประสีแดง (- - -) และค่าพยากรณ์โดยวิธีผสมระหว่างโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟแทนด้วยเส้นจุดสีเขียว (•••) พบว่าค่าพยากรณ์ที่ได้จากทั้งสองวิธีใกล้เคียงกับค่าจริง แต่ค่าพยากรณ์ที่ได้จาก

วิธีผสมระหว่างโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟใกล้เคียงกับค่าจริงมากกว่า และตารางที่ 5 จะเห็นได้ว่า RMSE และ MAPE โดยวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟมีค่าต่ำกว่า RMSE และ MAPE โดยวิธีโครงข่ายประสาทเทียม

4. วิจารณ์และสรุป

งานวิจัยนี้ได้นำเสนอการพยากรณ์ปริมาณความเข้มข้นของ PM2.5 ในอากาศรายชั่วโมง โดยใช้วิธีโครงข่ายประสาทเทียม และวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟ พบว่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยและเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยด้วยวิธีโครงข่ายประสาทเทียม คือ 2.4864 และ 7.2877 ตามลำดับ ขณะที่รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยและเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยด้วยวิธีผสมของโครงข่ายประสาทเทียมและห้วงโซ่มาร์คอฟ คือ 1.1890 และ 3.2972 ตามลำดับ ซึ่งจะเห็นว่าการใช้วิธี

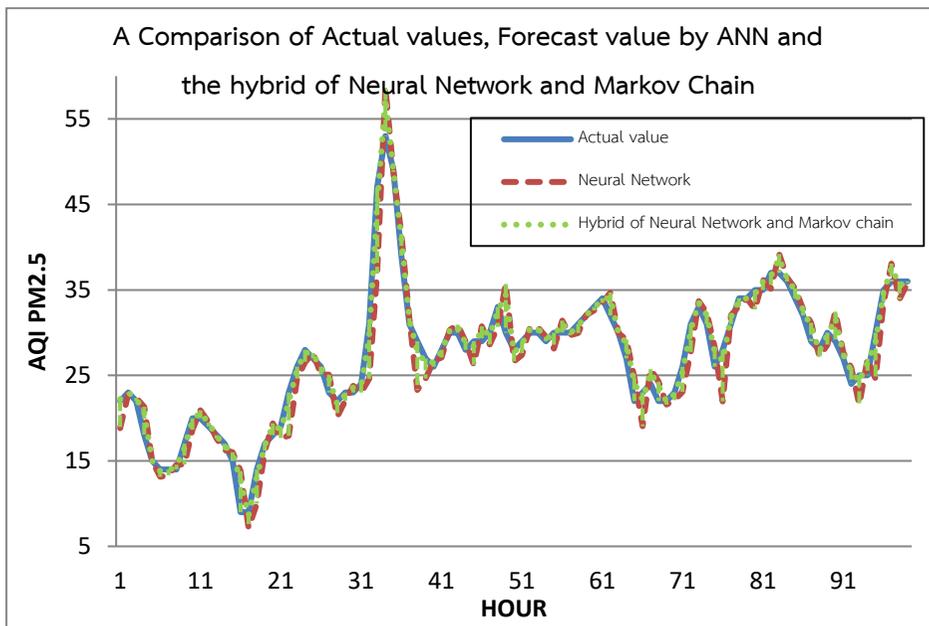


Figure 5 Comparisons between actual value and forecast value of PM2.5

ผสมของโครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟจะ
ให้ผลการพยากรณ์แม่นยำกว่าวิธีโครงข่ายประสาท
เทียม ซึ่งสอดคล้องกับงานวิจัยของ Dai และคณะ [12]
ที่ได้พยากรณ์ราคาตลาดหุ้นในระยะเวลาสั้นโดยใช้วิธี
โครงข่ายประสาทเทียมและห่วงโซ่มาร์คอฟ โดยกล่าว
ว่าวิธีผสมของโครงข่ายประสาทเทียมและห่วงโซ่
มาร์คอฟให้ความคลาดเคลื่อนในการพยากรณ์ต่ำกว่า
วิธีโครงข่ายประสาทเทียมเพียงอย่างเดียว ทั้งนี้การ
สร้างตัวแบบการพยากรณ์ในครั้งนี้เป็นประโยชน์ต่อ
การคาดการณ์ปริมาณความเข้มข้นของ PM2.5 เพื่อ
ทราบถึงระดับความรุนแรงของคุณภาพอากาศ

5. References

- [1] Pollution Control Department, Air Quality Index Data, Available Source: <http://air4thai.pcd.go.th/webV2/history>, October 1, 2020. (in Thai)
- [2] Inkhumhaeng, A., 2020, Creating the situations report of environmental health literacy on preventing the health impacts from dust particulate matter of less than 2.5 micrometers (PM2.5) of village health volunteers in ecological industrial urban areas, Research Report, Srinakharinwirot University, Bangkok, 137 p. (in Thai)
- [3] Asadollahfardi, G., Zangoeei, H. and Aria, S.H., 2016, Predicting PM2.5 concentrations using artificial neural networks and Markov chain, a case study Karaj city, Asian J. Atmospheric Environ. 10(2): 67-79.
- [4] Tongboonnak, K., 2018, Forecast of dust particles up to 10 microns (PM10), National Research Council of Thailand (NRCT), Research Report, Chiang Mai Rajaphat University, Chiang Mai, 36 p. (in Thai)
- [5] Kurt, A., Gulbagci, B., Karaca, F. and Alagha, O., 2008, An online air pollution forecasting system using neural networks, Env. Int. 34(2008): 592-598.
- [6] Muhammad, M., Shafiullah, S.M., Abu, N., Abduljamiu, A. and Hasan, Z., 2020, Soft computing applications in air quality modeling: Past, present and future, Sustain. J. 12(4045): 1-33.
- [7] Zakaria, N.N, Othman, M., Sokkalingam, R., Daud, H., Abdullah, L. and Kadir, E.A, 2019, Markov chain model development for forecasting air pollution index of Miri, Sarawak, Sustain. J. 11(19): 1-11.
- [8] Lamkamol, C., 2016, Book review competency based 70: 20: 10 learning model, Business Rev. 8(2): 219-221. (in Thai)
- [9] Patrick, H.W. , 1997, Artificial Intelligence, pp. 443-469, In Boonchote, K. (Ed.), Thai Keyphrases Extraction Using Artificial Neural Network, Department of Information Technology, Prince of Songkla University, Songkhla, 284 p. (in Thai)
- [10] Box, G.E.P., G.M. Jenkins and G.C. Reinsel, 1994, Time Series Analysis Forecasting and Control, 3rd Ed., Prentice Hall, Inc., Hoboken, NJ, 598 p.
- [11] Grabusts, P. and Zorins, A. , 2015, The influence of hidden neurons factor on

- neural network training quality assurance,
Int. Sci. 3: 76-81.
- [12] Dai, Y., Han, D. and Dai, W., 2014, Modeling
and computing of stock index forecasting
based on neural network and Markov
chain, Hindawi. J. 2014(1): 1-9.