



## KKU Engineering Journal

<http://www.en.kku.ac.th/enjournal/th/>

### โครงข่ายประสาทเทียมแบบประสานคำตอบเพื่อการกะประมาณปริมาณสุกรขุน A neural network ensemble models for pig size prediction

อาทิตย์ อภิโชติธนกุล และ ศุภชัย ปทุมนากุล\*

Arthit Apichottanakul and Supachai Pathumnakul\*

กลุ่มวิจัยระบบโซ่อุปทานและโลจิสติกส์ ภาควิชาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น จังหวัดขอนแก่น 40002

Supply Chain and Logistics System Research Unit, Department of Industrial Engineering, Faculty of Engineering,

Khon Kaen University, Khon Kaen, Thailand, 40002

Received February 2013

Accepted September 2013

#### บทคัดย่อ

บทความนี้เป็นการนำเสนอผลการวิจัย การพัฒนาโครงข่ายประสาทเทียมแบบประสานคำตอบเพื่อการกะประมาณสัดส่วนของสุกรขุนในแต่ละขนาด โดยโครงข่ายประกอบด้วยสมาชิก 3 ชนิด คือ โครงข่ายแบบเพอร์เซพตรอนหลายชั้นที่มีการเรียนรู้แพร่ย้อนกลับ เรเดียลเบสฟังก์ชัน และเจเนอรัลไลเซชัน นิวรอลเน็ตเวิร์ค และใช้วิธีการรวมคำตอบ 3 วิธี คือ ค่าเฉลี่ยอย่างง่าย ค่าเฉลี่ยแบบถ่วงน้ำหนัก และค่ามัธยฐาน ผลลัพธ์ที่ได้พบว่า วิธีการรวมคำตอบด้วยค่ามัธยฐานเป็นวิธีที่เหมาะสมในการประสานคำตอบของแต่ละสมาชิกและเมื่อนำไปใช้ในการประมาณสัดส่วนของขนาดสุกรนั้น โครงข่ายประสาทเทียมแบบประสานคำตอบมีความคลาดเคลื่อนด้วยค่า RMSE ต่ำกว่า 9 % เมื่อเทียบกับค่าจริงที่เกิดขึ้นในทุกๆ ขนาดของสุกร

**คำสำคัญ :** การพยากรณ์ผลผลิต โครงข่ายประสาทเทียมแบบประสานคำตอบ การวางแผนการจับสุกร โซ่อุปทานการชำแหละและแปรรูปสุกร

#### Abstract

The paper presents a neural network ensemble models for pig size prediction in swine fattening farm. This approach has been developed based on three methods: Multilayer perceptron with back-propagation neural network, Radial basis function and Generalize regression neural network. The solutions from three methods, then are combined using the Simple averaging, Weighted averaging and Median approaches. The results show that the developed model provide reasonable prediction solutions with the root-mean square error (RMSE) lower than 9.0 for all sizes of pigs.

**Keywords :** Production forecasting, Neural network ensemble, Pig procurement plan, Pork processing industry

\*Corresponding author:

Email address: [supa\\_pat@kku.ac.th](mailto:supa_pat@kku.ac.th)

## 1. บทนำ

ในอุตสาหกรรมการชำแหละและแปรรูปสุกรมี ปัญหาหนึ่งที่สำคัญ ก็คือ ความไม่แน่นอนของปริมาณ ผลผลิตสุกรมีชีวิตในแต่ละฟาร์ม ซึ่งมีความสำคัญและ ส่งผลต่อประสิทธิภาพในการดำเนินงานของขั้นตอนต่างๆ ที่เกี่ยวข้องในโซ่อุปทาน เช่น ฟาร์ม การวางแผนการผลิต ในฟาร์มและโรงชำแหละ การตลาดและจำหน่าย เป็นต้น เพื่อแก้ปัญหาเหล่านี้ รวมทั้งต้องการสร้างความมั่นใจใน คุณภาพและปริมาณของสุกรมีชีวิตที่จะนำไปใช้ในการ ชำแหละและแปรรูป ดังนั้น ฟาร์มและโรงชำแหละจึงมี ความร่วมมือกันในการจัดการการผลิตและการดำเนินงาน อย่างใกล้ชิด อย่างไรก็ตาม แม้ว่าจะมีความร่วมมือกัน อย่างใกล้ชิดแล้ว โซ่อุปทานก็ยังคงประสบปัญหาความไม่ แน่นนอนของสุกรขนาดต่างๆ ในแต่ละฟาร์ม ซึ่งเป็น ลักษณะตามธรรมชาติของสิ่งมีชีวิตที่ไม่สามารถควบคุม ได้หรือควบคุมได้ยาก เช่น ฟาร์มเดียวกันมีปัจจัย สภาพแวดล้อม การให้อาหาร การจัดการที่เหมือนกัน แต่ ปริมาณผลผลิตของสุกรในแต่ละขนาดที่ได้จากแต่ละ โรงเรือนอาจจะแตกต่างกันไป เป็นต้น ซึ่งความไม่แน่นอน นี้ทำให้การวางแผนการผลิตในโรงชำแหละและแปรรูปมี ความยุ่งยากและขาดประสิทธิภาพ

ในการวางแผนการผลิต สิ่งสำคัญที่จะต้องนำมา พิจารณาร่วม ประกอบด้วย สุกรมีชีวิตจากฟาร์ม คำสั่งซื้อ จากลูกค้า (Orders) ขึ้นส่วนสดแช่เย็นที่เหลือจากการผลิต (Remain chill) และสินค้าคงคลังแช่แข็ง (Stock frozen) เมื่อชำแหละสุกรหนึ่งตัวจะได้ชิ้นส่วนหลัก (Primal cut) หลายประเภท เช่น สะโพกหรือขาหลัง(Ham), ไหล่หรือ ขาหน้า (Shoulder), สันคอ (Collar), สันนอก (Loin), สันใน (Tender loin) และเนื้อส่วนท้องหรือสามชั้น (Belly) เป็นต้น โดยขนาดและน้ำหนักของชิ้นส่วนเหล่านี้จะแปรผันตาม ขนาดและพันธุ์ของสุกร สุกรที่มีขนาดต่างกันหรือพันธุ์ ต่างกันจะให้ชิ้นส่วนหลักแตกต่างกันไปด้วย เช่น สุกรที่มี

น้ำหนักประมาณ 120 กิโลกรัม จะให้ Ham ที่มีขนาดและ น้ำหนักแตกต่างจากสุกรในขนาด 90 กิโลกรัม เป็นต้น

โดยปกติเมื่อโรงชำแหละได้รับคำสั่งซื้อจากลูกค้า ฝ่ายวางแผนการผลิตจะทำการแปลงคำสั่งซื้อทั้งหมดที่ ได้รับให้อยู่ในรูปของจำนวนและขนาดของสุกรมีชีวิตที่ ต้องการในแต่ละวัน ซึ่งก็จะมีการวางแผนการจับและ ลำดับการจัดส่งสุกรของแต่ละฟาร์มให้โรงชำแหละตาม ความต้องการต่อไป ดังนั้นถ้านักวางแผนมีข้อมูลปริมาณ และขนาดของสุกรในแต่ละฟาร์มที่ไม่แม่นยำเพียงพอ ก็ จะส่งผลให้มีต้นทุนในการดำเนินงานและสินค้าคงคลังที่ สูงมากจนเกินไป เช่น ถ้านำเฉพาะสุกรขนาดเล็กเข้ามา ชำแหละก็จะไม่สามารถตอบสนองความต้องการของ ลูกค้าที่ต้องการชิ้นส่วนขนาดใหญ่ได้ และถ้าชิ้นส่วน ขนาดเล็กนั้นไม่เป็นที่ต้องการในขณะนั้นก็ต้องนำไปแช่ แข็งเก็บไว้ซึ่งก่อให้เกิดต้นทุนการจัดเก็บและเสื่อมสภาพ ในทางตรงกันข้าม ถ้านำเฉพาะสุกรขนาดใหญ่เข้ามา ชำแหละก็จะต้องมีการตัดแต่งชิ้นส่วนซึ่งทำให้เกิดต้นทุน จากเสียโอกาสในการจำหน่ายชิ้นส่วนขนาดใหญ่ เนื่องจากมีราคาที่สูงกว่าขนาดเล็ก เป็นต้น โดยปัจจัยที่ สำคัญ ในการจัดการโซ่อุปทานธุรกิจสุกร คือ ความสามารถในการจัดการการผลิตตามขนาดของสุกรมี ชีวิตที่จะได้รับจากฟาร์มให้สอดคล้องกับความต้องการ ของลูกค้า ดังนั้น การประมาณหรือการคาดการณ์ ปริมาณหรือจำนวนของสุกรขนาดต่างๆ ในแต่ละฟาร์มจึง เป็นสิ่งจำเป็นและมีความสำคัญต่อการตอบสนองความ ต้องการชิ้นส่วนของลูกค้าได้อย่างมีประสิทธิภาพ

ด้วยเหตุนี้ [1] ได้นำเสนอการประยุกต์ใช้โครงข่าย ประสาทเทียม (Artificial neural network, ANN) ในการ ประมาณการเจริญเติบโตของสุกรในแต่ละฟาร์ม ภายใต้ รูปแบบและระยะเวลาการเลี้ยง ทักษะของฟาร์ม เพศและ พันธุ์ของสุกรที่แตกต่างกัน ซึ่งให้ผลลัพธ์ที่ดีช่วยเพิ่มความ แม่นยำในการประมาณการณ์ผลผลิตสุกรและสามารถ นำไปใช้เป็นข้อมูลในการวางแผนการจับสุกรได้อีกด้วย

อย่างไรก็ตาม งานวิจัย [1] ดังกล่าวนั้นอาศัยตัวแบบ ANN แบบเดียวในการประมาณ ซึ่งหลายๆ งานวิจัย [2, 3, 4, 5] ได้ชี้ให้เห็นว่าสามารถเพิ่มความแม่นยำและประสิทธิภาพได้โดยการสร้างตัวแบบหลายๆ ตัว (สมาชิก) และทำการประสานคำตอบจากตัวแบบเหล่านั้น ซึ่งการรวมคำตอบจากสมาชิกแต่ละตัวนี้ เรียกว่า ตัวแบบการประสานคำตอบ (Ensemble models) ซึ่งมีตัวแบบชนิดต่างๆ ที่ได้รับความนิยมนำมาสร้างเป็นสมาชิกเพื่อการประสานหรือรวมคำตอบ เช่น ตัวแบบโครงข่ายประสาทเทียม (ANN) ตัวแบบสมการถดถอย (Regression models) ต้นไม้ตัดสินใจ (Decision trees) และซัพพอร์ตเวกเตอร์ แมชชีน (Support vector machine, SVM) เป็นต้น โดยตัวแบบการประสานคำตอบที่มีเฉพาะ ANN เป็นสมาชิก เรียกว่าโครงข่ายประสาทเทียมแบบประสานคำตอบ (Neural network ensemble model, NNE) ซึ่งถูกนำไปใช้ในการแก้ปัญหาในด้านต่างๆ ในงานวิจัยเป็นจำนวนมากและยังให้ประสิทธิภาพที่ดีกว่าการใช้เพียง ANN แบบเดียว ตัวอย่างเช่น การคาดการณ์สภาวะการล้มละลายของบริษัทในประเทศเกาหลี [4] การพยากรณ์อัตราแลกเปลี่ยน [5] การพยากรณ์อนุกรมเวลา [8] และการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ [10] เป็นต้น

ดังนั้น งานวิจัยนี้จึงสนใจที่จะนำ NNE มาประยุกต์ใช้ในการประมาณปริมาณของสุกรขนาดต่างๆ ในแต่ละฟาร์มเพื่อนำไปใช้เป็นข้อมูลในการวางแผนการจับสุกรส่งโรงชำแหละและแปรรูป และเนื่องจากว่า ANN นั้นมีหลายประเภทซึ่ง [10] ได้แบ่งตามลักษณะการเรียนรู้ออกเป็น 3 ประเภท คือ แบบมีผู้สอน (Supervised learning) แบบไม่มีผู้สอน (Unsupervised learning) และแบบเสริมกำลัง (Reinforcement learning) อย่างไรก็ตามงานวิจัยนี้อาศัยแนวทางของ [1] ในการดำเนินงานวิจัย ดังนั้นตัวแบบสมาชิกใน NNE จะประกอบด้วย ANN แบบมีผู้สอนจำนวน 3 ชนิด คือ (1)

แบบเพอร์เซพตรอนหลายชั้นที่มีการเรียนรู้แพร่ย้อนกลับ (Multilayer perceptron with back-propagation neural network, MLP-BP), (2) แบบเรเดียลเบซิสฟังก์ชัน (Radial basis function, RBF) และ (3) เจเนอรัลไลซ์รีเกรสชัน นิวรอลเน็ตเวิร์ค Generalize regression neural network (GRNN)

## 2. วิธีการการวิจัย

วิธีการประสานคำตอบ (Ensemble methods) ได้รับความนิยมและถูกนำไปใช้ในการแก้ปัญหาต่างๆ ในงานวิจัยด้านต่างๆ เป็นจำนวนมาก และเพื่อให้ได้รับผลลัพธ์ที่ดีนั้น วิธีการนี้จะต้องพิจารณาสิ่งที่สำคัญใน 2 ประเด็น [6] คือ จะสร้างสมาชิกอย่างไรให้มีความแม่นยำและหลากหลายในการเรียนรู้จากข้อมูล และจะทำการรวมคำตอบเหล่านั้นอย่างไรให้มีประสิทธิภาพ ดังนั้นวิธีการต่างๆ เพื่อสร้างสมาชิกในตัวแบบนี้จึงถูกพัฒนาขึ้นมามากมายและได้รับความนิยมเป็นอย่างมาก เช่น วิธี Bagging, Boosting และ Cross-validation เป็นต้น อย่างไรก็ตาม [2] ได้แบ่งวิธีที่ใช้ในการสร้างตัวแบบการประสานคำตอบออกเป็น 3 ประเภท ดังนี้คือ (1) วิธีการที่เลือกหรือสร้างข้อมูลสำหรับฝึกสอนแบบหลากหลายชุดขึ้นมาจากข้อมูลดั้งเดิมหนึ่งชุด (2) วิธีการที่มุ่งเน้นการสร้างตัวแบบโครงข่ายผู้เชี่ยวชาญหรือสมาชิกที่แตกต่างกัน (3) วิธีการที่มุ่งการประสานหรือรวมกลุ่มสมาชิกและคำตอบของสมาชิกเหล่านั้น โดยในตอนนี้จะกล่าวถึงการพัฒนา NNE โดยเริ่มจากข้อมูลที่ใช้ในการวิจัย ตัวแบบ ANN ทั้ง 3 ชนิดที่เป็นสมาชิกใน NNE วิธีการในการรวมคำตอบจากแต่ละสมาชิก และภาพรวมของวิธีการที่นำเสนอ โดยมีรายละเอียดดังนี้

### 2.1 ข้อมูลสำหรับพัฒนาและทดสอบ NNE

ข้อมูลที่ใช้ในงานวิจัยนี้รวบรวมมาจากฟาร์มสุกรขุนของบริษัทกรณีศึกษา โดยแบ่งออกเป็นชุดฝึกสอนและ

ชุดทดสอบความแม่นยำ ซึ่งประกอบด้วยข้อมูลจากฟาร์มสุกรแม่พันธุ์ และฟาร์มสุกรขุนทั้งหมด 112 ฟาร์ม ในแต่ละวงรอบการเลี้ยงและการจับสุกรส่ง โรงชำแหละรายละเอียดมีดังนี้ (1) ข้อมูลสำหรับฝึกสอนและพัฒนา NNE จำนวน 299 ข้อมูล ในช่วงเดือนกันยายน พ.ศ. 2551 – มีนาคม พ.ศ. 2554 (นำมาจากงานวิจัย [1]) และ (2) ข้อมูลสำหรับทดสอบประสิทธิภาพความแม่นยำ จำนวน 116 ข้อมูล ซึ่งเป็นข้อมูลในช่วงเดือนเมษายน – พฤศจิกายน พ.ศ. 2554 โดยข้อมูลทั้ง 2 ชุด แบ่งออกเป็นข้อมูลเข้า (Input) สำหรับแต่ละสมาชิกของ NNE ซึ่งมีปัจจัยหลัก 8 ปัจจัย และแบ่งออกเป็นตัวแปรได้ทั้งหมดจำนวน 23 ตัวแปร และข้อมูลออก (Output) มีทั้งหมดจำนวน 7 ตัวแปร ที่เป็นสัดส่วนของปริมาณสุกรในขนาดที่ 1-7 (%) ตามงานวิจัยที่เสนอโดย [1] ซึ่งข้อมูล Input มีรายละเอียดดังนี้

(1) ฟาร์มแม่พันธุ์ แหล่งที่มาของลูกสุกรที่ส่งไปยังฟาร์มต่างๆ ซึ่งแบ่งออกเป็น 11 ฟาร์ม นั่นคือ มีปัจจัยด้านฟาร์มแม่พันธุ์ จำนวน 11 ปัจจัย และอยู่ในรูปตัวแปรหุ่น (Dummy variable) จะมีค่าระหว่าง 0 กับ 1 เท่านั้น (ตัวอย่างเช่น ถ้าฟาร์มรับลูกสุกรมาจากฟาร์มแม่พันธุ์ A จะมีค่าเป็น 1 นอกจากนั้นเป็น 0)

- (2) ปริมาณลูกสุกรแรกเข้าฟาร์ม (ตัว)
- (3) อายุเฉลี่ยของลูกสุกรแรกเข้าฟาร์ม (วัน)
- (4) น้ำหนักเฉลี่ยของลูกสุกรแรกเข้าฟาร์ม (กก.)
- (5) อัตราการการเลี้ยงรอดของแต่ละฟาร์ม (%)
- (6) ระยะเวลาในการเลี้ยงสุกร (วัน)
- (7) คะแนนการจัดการฟาร์ม (หน่วย)
- (8) ปริมาณของอาหารสูตรที่ 1-6 ที่สุกรกินเฉลี่ยต่อตัว (กก./ตัว) นั่นคือ มีตัวแปรทั้งหมด 6 ตัวแปรแทนสูตรอาหารแต่ละชนิด

ส่วนการจัดเตรียมข้อมูลสำหรับพัฒนา NNE นั้นในงานวิจัยนี้ใช้เทคนิค 5-fold Cross-validation สำหรับฝึกสอน ANN แต่ละตัว (ในงานวิจัยนี้ใช้ ANN 3 ชนิด คือ

MLP-BP, RBF และ GRNN) ที่เป็นสมาชิก NNE โดยข้อมูลจะถูกแบ่งออกเป็น 5 ชุด เท่าๆ กัน ซึ่งจะกำหนดให้ข้อมูล 1 ชุด เป็นชุดทดสอบ (Test data) และอีก 4 ชุดที่เหลือเป็นชุดฝึกสอน (Train data) ซึ่งจะเปลี่ยนชุดทดสอบไปเรื่อยๆ ทีละชุดจนครบหมดทุกชุดข้อมูล ดังแสดงในรูปที่ 1

Subset1	Test	Train	Train	Train	Train
Subset2	Train	Test	Train	Train	Train
Subset3	Train	Train	Test	Train	Train
Subset4	Train	Train	Train	Test	Train
Subset5	Train	Train	Train	Train	Test

ANN1   ANN2   ANN3   ANN4   ANN5

รูปที่ 1 ตัวอย่างของเทคนิค 5-fold cross-validation

## 2.2 โครงข่าย MLP-BP

MLP-BP [1] ได้รับความนิยมและถูกนำไปใช้ในงานวิจัยเป็นจำนวนมาก เนื่องจากความสามารถในการทำนายปัญหาที่ซับซ้อนได้เป็นอย่างดี ตัวอย่าง เช่น การประมาณการเจริญเติบโตของสุกร [1] การพยากรณ์ความต้องการข้าวไทยจากต่างประเทศ [11] และการพยากรณ์ต้นทุนของเสียในอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ [12] เป็นต้น ดังนั้น งานวิจัยนี้จึงนำมาใช้เป็นหนึ่งในสมาชิกของ NNE ในการประมาณผลผลิตสุกร โดยโครงสร้างของโครงข่ายแบบนี้ประกอบด้วย 3 ชั้น คือ ชั้นข้อมูลเข้า (Input layer) ชั้นซ่อน (Hidden layers) และชั้นข้อมูลออก (Output layer) เพื่อทดลองหาโครงสร้างและสถาปัตยกรรมที่เหมาะสมสำหรับนำไปเป็นสมาชิกของ NNE ในงานวิจัยนี้จึงกำหนดพารามิเตอร์ที่เกี่ยวข้องดังนี้ กำหนดชั้นซ่อนให้มี 1- 2 ชั้น จำนวนโนด (Node) ในชั้นซ่อนมีค่า 10-90 โหนด ฟังก์ชันกระตุ้น (Activation function) คือ Tansig และ Logsig และใช้ Scaled

conjugate gradient (Trainscg) และ Levenberg-Marquardt (Trainlm) เป็นฟังก์ชันในการฝึกสอน

2.3 โครงข่าย RBF

โครงข่าย RBF โดยทั่วไปเป็น ANN แบบป้อนไปข้างหน้าแบบหลายชั้น ซึ่งประกอบไปด้วย 3 ชั้น คือ ชั้นข้อมูลเข้า ชั้นซ่อน และชั้นข้อมูลออก เหมือนกับ MLP-BP แต่ที่แตกต่างกันก็คือ RBF มีชั้นซ่อนแค่เพียงชั้นเดียว และฟังก์ชันกระตุ้นที่เชื่อมต่อกันระหว่างชั้น Input กับชั้นซ่อนจะใช้ฟังก์ชันเกาส์เซียน (Gaussian function) หรือ Basis kernel function จึงทำให้โดยปกติแล้ว RBF จะใช้เวลาในการฝึกสอนที่เร็วกว่า MLP-BP [5] และเมื่อนำไปใช้กับปัญหาที่มีความยากและซับซ้อนมากขึ้น การลู่เข้าสู่ค่าความผิดพลาด (Error) ที่ต่ำเพื่อให้ได้คำตอบที่ต้องการก็จะใช้เวลาน้อยกว่าอีกด้วย

2.4 โครงข่าย GRNN

GRNN เป็นโครงข่ายแบบ RBF ชนิดหนึ่ง [7] ที่ถูกพัฒนาขึ้นมาเพื่อแก้ปัญหาข้อเสียบางประการของ RBF ที่จะต้องใช้ฟังก์ชันจำนวนมากในการคำนวณ ดังนั้น GRNN จึงมีเพียงแค่พารามิเตอร์ 1 ตัวเท่านั้น ที่จะต้องใช้ในการฝึกสอนตัวโครงข่าย นั่นก็คือ ค่าปรับให้เรียบ (Smoothing parameter) ซึ่งโครงข่ายนี้ประกอบไปด้วย 4 ชั้น คือ ชั้นข้อมูลเข้า ชั้นการจำลองรูปแบบ (Pattern layer) ชั้นผลรวม (Summation layer) และชั้นข้อมูลออก ส่วนรายละเอียดการคำนวณในแต่ละชั้นดูที่ [7, 8]

เนื่องจากเป็นวิธีการที่ง่ายและมีประสิทธิภาพที่ดี สามารถฝึกสอนหรือเรียนรู้ข้อมูลได้อย่างรวดเร็วจึงได้รับความนิยมและถูกนำไปใช้ในงานวิจัยเพื่อการเรียนรู้และจัดจำรูปแบบของข้อมูลในปัญหาต่างๆ เช่น การจัดจำรูปแบบ [7] และการพยากรณ์อนุกรมเวลา [8] เป็นต้น

2.5 วิธีการรวมคำตอบ (Combination methods)

ในการรวมคำตอบจากแต่ละสมาชิกเพื่อประสานกันเป็นคำตอบเดียวสำหรับตัวแบบประสานคำตอบนั้นมีหลายวิธีการที่ได้รับการพัฒนาขึ้นมา บางวิธีเหมาะกับปัญหาที่เป็นการจัดจำแนกข้อมูล (Classification) บางวิธีทำงานได้ดีกับปัญหาในลักษณะของการประมาณค่าหรือการวิเคราะห์การถดถอย เป็นต้น แต่ในที่นี้จะกล่าวถึง 3 วิธีที่ใช้ในงานวิจัยนี้เท่านั้น คือ

(1) ค่าเฉลี่ยอย่างง่าย (Simple averaging, SA)

ซึ่งเป็นวิธีหนึ่งที่ย่างที่สุดและได้รับความนิยมมากที่สุด [2] ในการรวมคำตอบจากแต่ละสมาชิก ดังสมการ (1)

$$NE = \frac{1}{k} \sum_{i=1}^k NN_i \tag{1}$$

เมื่อ NE คือ ผลลัพธ์จากการรวมคำตอบ และ NN<sub>i</sub> คือ ผลลัพธ์จากสมาชิก i

(2) ค่าเฉลี่ยแบบถ่วงน้ำหนัก (Weighted averaging, WA)

วิธีนี้ทุกๆ สมาชิกในโครงข่ายจะมีค่าถ่วงน้ำหนักที่เหมาะสมกับประสิทธิภาพของแต่ละสมาชิกที่แตกต่างกันไป โดยในงานวิจัยนี้ใช้ Genetic algorithm (GA) ในการกำหนดน้ำหนักความสำคัญที่เหมาะสมที่สุดของสมาชิกแต่ละตัว ดังสมการ (2)

$$NE = \sum_{i=1}^k w_i NN_i ; \sum_{i=1}^k w_i = 1 \tag{2}$$

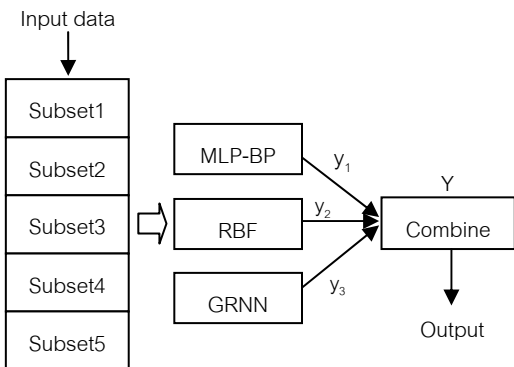
เมื่อ w<sub>i</sub> คือ ค่าน้ำหนักของสมาชิก i และใช้ค่าความคลาดเคลื่อนกำลังสองน้อยที่สุด (Mean square error, MSE) เป็นเกณฑ์ในการหาน้ำหนักที่เหมาะสมที่สุดของสมาชิกแต่ละตัว

(3) ค่ามัธยฐาน (Median, ME) คือ ค่าที่มี

ตำแหน่งอยู่กึ่งกลางของข้อมูลทั้งหมด เมื่อเรียงข้อมูลตามลำดับจากน้อยไปมาก หรือจากมากไปน้อย

2.6 วิธีการที่นำเสนอ

ในส่วนนี้จะกล่าวถึงวิธีการในการพัฒนา NNE เพื่อการประมาณผลผลิตสุกร โดยมีโครงสร้างแสดงในรูปที่ 2 ซึ่งเริ่มต้นด้วยการแบ่งข้อมูลเข้า (Input) ออกเป็น 5 ส่วนเท่าๆ กัน และให้สมาชิกของ NNE ทั้ง 3 ชนิด คือ MLP-BP, RBF และ GRNN เรียนรู้ข้อมูลในแต่ละชุด (ตามรูปที่ 1) และใช้วิธีการรวมคำตอบ 3 วิธี คือ วิธี SA, WA และ ME ในการประสานคำตอบจากสมาชิกแต่ละตัว ซึ่งก็จะได้คำตอบหรือ Output ของ NNE และเนื่องจากงานวิจัยนี้ได้ประมาณผลผลิตสุกรในแต่ละฟาร์มซึ่งก็คือสัดส่วนของปริมาณสุกร มีชีวิตในขนาดที่ 1 – 7 ที่อยู่ในฟาร์มต่างๆ ดังนั้น Output ของ NNE จึงมี 7 ตัว แต่ในการพัฒนา NNE เพื่อคำนวณ Output ในงานวิจัยนี้จะไม่คำนวณทั้ง 7 ตัวพร้อมกัน แต่จะแยกพัฒนาและคำนวณที่ละขนาด นั่นคือ จะมีตัวแบบ NNE สำหรับแต่ละขนาดแยกกัน เช่น NNE สำหรับสุกรขนาดที่ 1 (Multi inputs one output) เป็นต้น โดยลำดับขั้นตอนการดำเนินงานวิจัยและการพัฒนา NNE แสดงในรูปที่ 3

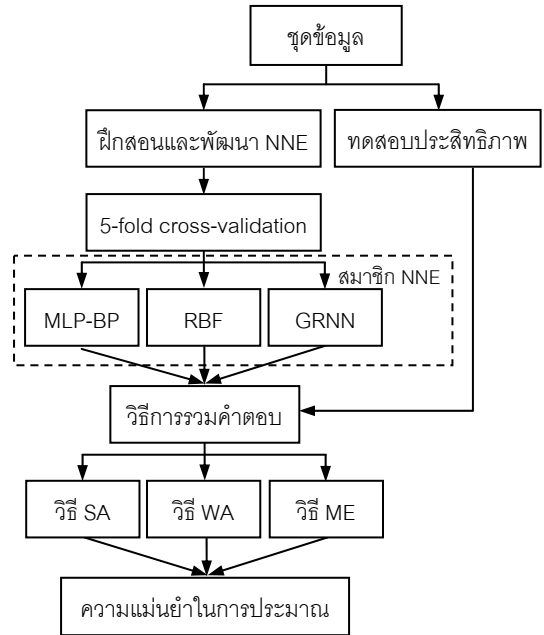


รูปที่ 2 แสดงโครงสร้างระบบของ NNE

3. ผลการวิจัย

ในส่วนนี้จะนำเสนอผลการพัฒนาและการทดสอบประสิทธิภาพของ NNE โดยจะใช้มาตรวัดความแม่นยำ คือ RMSE (Root mean square error) และ MAE (Mean absolute error) สามารถคำนวณได้ดังสมการ (3) และ

(4) ตามลำดับ ซึ่งใช้วัดความแม่นยำของการประมาณ ถ้าค่าที่ได้มีค่าต่ำและมีค่าเข้าใกล้ศูนย์ ก็แสดงว่ามีความแม่นยำสูง



รูปที่ 3 แสดงลำดับขั้นตอนการดำเนินงานวิจัย

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (Fa_j - Fp_j)^2}{n}} \tag{3}$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |Fa_j - Fp_j| \tag{4}$$

เมื่อ  $n$  คือ จำนวนข้อมูลทั้งหมด  $Fa_j$  และ  $Fp_j$  คือ ค่าจริงและค่าพยากรณ์ ตามลำดับ

3.1 ผลการพัฒนาตัวแบบ NNE

จากการพัฒนาตัวแบบ NNE สำหรับประมาณผลผลิตสุกร ผลลัพธ์แสดงในตารางที่ 1 สำหรับข้อมูลชุดฝึกสอนและพัฒนา โดยวิธีการรวมคำตอบสำหรับ NNE ทั้ง 3 วิธี คือ วิธี SA, WA และ ME พบว่า วิธี WA และ ME ให้ความแม่นยำที่ใกล้เคียงกัน ถึงแม้ว่าวิธี ME จะมีความแม่นยำมากกว่าในการประมาณสัดส่วนของสุกรในทุกๆ

ขนาด พิจารณาค่า RMSE พบว่า วิธีการรวมคำตอบแบบ ME ให้ความแม่นยำมากกว่าวิธีการอื่นๆ ในการประมาณขนาดตุกรที่ 1, 2, 3, 5 และ 7 ส่วนขนาดที่ 4 และ 6 นั้นวิธี WA ให้ความแม่นยำมากกว่าวิธีการรวมคำตอบแบบอื่นๆ และเมื่อพิจารณาค่า MAE พบว่า วิธีการรวมคำตอบแบบ ME ให้ความแม่นยำมากกว่าวิธีการอื่นๆ สำหรับการประมาณสัดส่วนของตุกรขนาดที่ 1-7 ดังนั้น วิธีการรวมคำตอบ ME และ WA จึงมีความเหมาะสมมากกว่าวิธี SA ที่จะนำไปใช้ในตัวแบบ NNE เพื่อประมาณผลผลิตตุกร

3.2 การทดสอบประสิทธิภาพความแม่นยำของ NNE

เมื่อทำการพัฒนา NNE ตามแนวทางในรูปที่ 1, 2 และ 3 จากชุดข้อมูลสำหรับฝึกสอนและพัฒนาและได้ผลลัพธ์ที่แสดงในตารางที่ 1 แล้ว หลังจากนั้นก็นำตัวแบบ NNE ไปใช้ในการประมาณผลผลิตตุกร ในสถานการณ์จริงที่เกิดขึ้น เพื่อทดสอบประสิทธิภาพความแม่นยำจาก

การใช้งาน โดยใช้ข้อมูลสำหรับทดสอบประสิทธิภาพความแม่นยำ จำนวน 116 ข้อมูลในการประมาณการณ์และทดสอบ ผลที่ได้แสดงในตารางที่ 2

พิจารณาค่า RMSE พบว่า วิธีการรวมคำตอบแบบ WA สำหรับตัวแบบ NNE ให้ความแม่นยำมากกว่าวิธีการอื่น เมื่อใช้ประมาณสัดส่วนของตุกรในขนาดที่ 1, 2 และ 3 ส่วนวิธี ME ให้ความแม่นยำมากกว่าวิธีการอื่นๆ ในขนาดที่ 4 และ 6 และวิธี SA ให้ความแม่นยำมากกว่าวิธีการอื่นๆ ในขนาดที่ 5 และ 7

พิจารณาค่า MAE พบว่า วิธีการรวมคำตอบแบบ WA สำหรับตัวแบบ NNE ให้ความแม่นยำมากกว่าวิธีการอื่น เมื่อใช้ประมาณสัดส่วนของตุกรในขนาดที่ 1, 2, 3 และ 5 ส่วนวิธี ME ให้ความแม่นยำมากกว่าวิธีการอื่นๆ ในขนาดที่ 4, 6 และ 7

ตารางที่ 1 ผลการประมาณผลผลิตตุกร สำหรับข้อมูลชุดฝึกสอนและพัฒนาตัวแบบ NNE

NNE		วิธีการรวมคำตอบ					
		วิธี SA		วิธี WA		วิธี ME	
ขนาดตุกร	ช่วงน้ำหนัก (กก.)	MAE	RMSE	MAE	RMSE	MAE	RMSE
S1	น้อยกว่า 87	0.99	1.42	0.83	1.22	0.28	0.68
S2	87 – 91	0.64	0.83	0.46	0.65	0.07	0.25
S3	92 – 96	0.73	0.95	0.62	0.86	0.11	0.32
S4	97 – 101	3.14	3.87	1.63	2.06	1.44	2.61
S5	102 – 117	2.68	3.38	1.73	2.27	0.79	1.94
S6	118 – 122	1.00	1.28	0.74	0.99	0.67	1.23
S7	มากกว่า 122	1.20	1.58	1.00	1.38	0.54	0.96
โดยเฉลี่ย (Avg.)		1.48	1.90	1.00	1.35	0.56	1.14

**ตารางที่ 2** ประสิทธิภาพในการประมาณผลผลิตสุกรของตัวแบบ NNE และ ANN [1]

ขนาดสุกร	วิธีการรวมคำตอบในตัวแบบ NNE							
	วิธี SA		วิธี WA		วิธี ME		ANN [1]	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
S1	5.50	8.61	5.42	8.11	5.46	8.40	5.56	7.98
S2	2.41	3.30	2.34	3.14	2.36	3.35	2.18	2.79
S3	2.88	3.67	2.63	3.35	2.82	3.80	2.98	3.79
S4	3.88	4.88	3.82	4.59	3.07	3.81	5.00	6.99
S5	6.93	8.47	6.81	8.84	7.15	8.70	8.79	11.50
S6	3.08	3.76	3.07	3.81	2.52	3.25	2.72	3.50
S7	4.74	6.99	4.86	7.27	4.71	7.04	4.06	5.62
เฉลี่ย (Avg.)	4.20	5.67	4.14	5.59	4.01	5.48	4.47	6.02

### 3.3 เปรียบเทียบความแม่นยำของ NNE และ ANN ที่พัฒนาโดย [1]

เนื่องจากงานวิจัยนี้อาศัย [1] เป็นแนวทางในการพัฒนาตัวแบบ NNE ดังนั้น ส่วนนี้จึงเปรียบเทียบผลการประมาณผลผลิตสุกร โดยใช้ข้อมูลสำหรับทดสอบประสิทธิภาพความแม่นยำ เพื่อทดสอบว่าตัวแบบ NNE นั้นจะช่วยทำให้ผลการประมาณผลผลิตสุกรดีขึ้นจริงหรือไม่เมื่อเทียบกับ ANN แบบเดียวกันในงานวิจัยของ [1] และผลลัพธ์ที่ได้แสดงไว้ในตารางที่ 2 สามารถสรุปได้ดังนี้

เมื่อพิจารณาค่า MAE และ RMSE พบว่า ANN [1] มีความแม่นยำมากกว่า NNE ในสุกรขนาดที่ 2 และ 7 โดยรูปที่ 4 เป็นตัวอย่างที่แสดงผลของการเปรียบเทียบความแม่นยำของการประมาณผลผลิตสุกรขนาดที่ 2 ซึ่งจะพบว่า ANN [1] ให้ความแม่นยำที่ดีกว่า ส่วน NNE ที่มีการรวมคำตอบด้วยวิธี ME มีความแม่นยำมากกว่า ANN [1] ในสุกรขนาดที่ 4, 5 และ 6 โดยที่สุกรในขนาดที่ 1 และ 3 นั้นตัวแบบทั้งสองยังให้ความแม่นยำที่ใกล้เคียงกัน

### 4. การอภิปรายผล

พิจารณาผลการพัฒนาตัวแบบ NNE ตามตารางที่ 1 สามารถสรุปได้ว่า วิธีการรวมคำตอบ ME ให้ความแม่นยำมากกว่าวิธีการอื่นๆ ในการประมาณสัดส่วนสุกรทุกขนาด เมื่อใช้มาตรฐานทั้งค่า MAE และ RMSE แม้ว่าวิธี WA จะมีค่า RMSE ที่ต่ำกว่าในสุกรขนาดที่ 4 และ 6 แต่ก็ได้ไม่ได้แตกต่างกันมากนักและมีค่าใกล้เคียงกับวิธี ME

พิจารณาผลการทดสอบประสิทธิภาพความแม่นยำของตัวแบบ NNE เมื่อนำไปใช้ในงานตามตารางที่ 2 สามารถสรุปได้ว่า วิธีการรวมคำตอบแบบ ME ก็ยังให้ผลที่ดีในการประมาณสัดส่วนสุกรเกือบทุกขนาด แม้ว่าวิธี WA จะมีค่า RMSE และค่า MAE ที่ต่ำกว่าในบางขนาดของสุกร แต่ค่าก็ไม่ได้แตกต่างกันมากนักและมีค่าใกล้เคียงกับวิธี ME ซึ่งโดยรวมแล้ววิธี ME ก็ยังคงเป็นวิธีการรวมคำตอบสำหรับ NNE ที่ให้ความแม่นยำและน่าเชื่อถือในการประมาณสัดส่วนขนาดของสุกร และจากตารางที่ 2 พบว่า เมื่อนำตัวแบบ NNE ไปใช้ประมาณ ก็



พบว่า สัดส่วนของสุกรในทุกขนาดมีค่าความคลาดเคลื่อนต่ำกว่า 9 % จากค่าสัดส่วนจริงที่เกิด ณ ฟาร์มสุกร

พิจารณาผลการทดสอบและเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ NNE ที่มีการรวมคำตอบด้วยวิธี ME และ ANN [1] หรือโครงข่ายประสาทเทียมแบบเดียวที่พัฒนาโดย [1] ซึ่งพบว่า NNE ให้ผลการประมาณสุกรในแต่ละขนาดที่แตกต่างกัน คือ มีค่าแม่นยำกว่าในบางขนาด น้อยกว่าในบางขนาดและใกล้เคียงสำหรับบางขนาด เมื่อเทียบกับ ANN [1] โดยเมื่อพิจารณาในภาพรวมแล้วก็สามารถสรุปได้ว่า NNE ให้ความแม่นยำในการประมาณสุกรมากกว่า ANN [1] แม้ว่าจะมีบางขนาดที่ NNE มีความแม่นยำน้อยกว่าแต่ค่าก็ไม่ได้แตกต่างกันมากนัก นอกจากนี้ ผลการเปรียบเทียบยังแสดงให้เห็นว่าการพัฒนา NNE อาจจะต้องมีการปรับปรุงในประเด็นต่างๆ ดังนี้ (1) สมาชิกใน NNE อาจจะทำให้คำตอบที่ไม่ดี อาจจะต้องมีการลดหรือเพิ่มจำนวนสมาชิก เช่น นำ ANN [1] มาเพิ่มเป็นสมาชิกเป็นต้น (2) การแบ่งข้อมูลด้วยวิธี 5-fold Cross-validation อาจจะไม่เหมาะสม ซึ่งก็อาจจะเพิ่มเป็น 10-fold Cross-validation โดยอาจจะให้ความแม่นยำที่ดีกว่าและ (3) วิธีการรวมคำตอบที่ใช้ อาจจะยังไม่เหมาะสมหรือให้ความแม่นยำที่ดีมากเพียงพอ ซึ่งอาจจะต้องนำวิธีอื่นๆ มาใช้ เช่น วิธีเคเน็ยเรสเนเบอร์ (K-nearest neighbor, K-NN) วิธีการถดถอยกำลังสองน้อยที่สุดบางส่วน (Partial least square regression, PLS) และวิธีโครงข่ายประสาทเทียม เป็นต้น

## 5. สรุป

บทความนี้ นำเสนอผลการวิจัย การพัฒนา NNE เพื่อการกะประมาณสัดส่วนของสุกรขุนในแต่ละขนาด ที่ประกอบด้วยสมาชิก 3 ชนิด คือ MLP-BP, RBF และ GRNN โดยใช้วิธีการรวมคำตอบ 3 วิธี คือ วิธี SA, WA และ ME ซึ่งพบว่า วิธีการรวมคำตอบแบบ ME เป็นวิธีที่

เหมาะสมในการประสานคำตอบของสมาชิกแต่ละตัว และเมื่อนำไปใช้ในการประมาณสัดส่วนของขนาดสุกรนั้น ตัวแบบ NNE มีค่าความคลาดเคลื่อนต่ำกว่า 9 % จากค่าจริงที่เกิดขึ้นในทุกๆ ขนาดของสุกร ดังนั้น ตัวแบบ NNE จึงมีความเหมาะสมที่จะนำไปใช้เป็นเครื่องมือในการประมาณสัดส่วนขนาดของสุกร เพื่อช่วยสนับสนุนการตัดสินใจในการวางแผนการจับและลำดับการจัดส่งสุกรให้โรงฆ่าและของแต่ละฟาร์มให้สอดคล้องกับความต้องการเพื่อตอบสนองต่อความต้องการของลูกค้าได้อย่างมีประสิทธิภาพและด้วยต้นทุนการดำเนินงานในโซ่อุปทานที่ต่ำ ซึ่งจะสามารถช่วยเพิ่มศักยภาพในการแข่งขันของอุตสาหกรรมต่อไป

## 6. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนสนับสนุนจากสำนักงานกองทุนสนับสนุนการวิจัย (สกว.) ภายใต้ทุน คปก.-อุตสาหกรรม ในทุนเลขที่ PHD/0074/2552

## 7. เอกสารอ้างอิง

- [1] Apichottanakul A, Pathumnakul S, Piewthongngam K. The role of pig size prediction in supply chain planning. *Biosystems Engineering*. 2012; 113: 298- 307.
- [2] Jafari SA, Mashohor S, Jalali Varnamkhasti M. Committee neural networks with fuzzy genetic algorithm. *Journal of Petroleum Science and Engineering*. 2011; 76: 217- 223.
- [3] Donate JP, Cortez P, Sánchez GG, de Miguel AS. Time series forecasting using a weighted cross-validation evolutionary artificial neural network ensemble. *Neurocomputing*. 2013; 109(3): 27-32.
- [4] Kim M-J, Kang D-K. Ensemble with neural networks for bankruptcy prediction. *Expert Systems with Applications*. 2010; 37: 3373- 3379.

- [5] Yu L, Lai KK, Wang S. Multistage RBF neural network ensemble learning for exchange rate forecasting. *Neuro-computing*. 2008; 71: 3295-3302.
- [6] Chen S, Wang W, van Zuylen. Construct support vector machine ensemble to detect traffic incident. *Expert Systems with Applications*. 2009; 36: 10976 – 10986.
- [7] Polat Ö, Yildirim T. Genetic optimization of GRNN for pattern recognition without feature extraction. *Expert Systems with Applications*. 2008; 34: 2444 – 2448.
- [8] Gheyas IA, Smith LS. A novel neural networks ensemble architecture for time series forecasting. *Neurocomputing*. 2011; 74: 3855- 3864.
- [9] Danaipong C, Kritchana K. Yield prediction using artificial neural networks. *KKU Eng J*. 2007; 34(4): 465 – 475. (In Thai).
- [10] Banchar A. Unsupervised neural networks and its applications. *KKU Eng J*. 2012; 39(4): 415 – 427. (In Thai).
- [11] Arthit A, Supachai P, Kullapapruk P. Thai rice exporting demand forecasting using artificial neural network. *KKU Eng J*. 2009; 36(1): 17-25. (In Thai).
- [12] Phattarasaya T, Athakorn K. Development of scrap cost forecasting model: A case study in hard disk drive company. *KKU Eng J*. 2012; 39(3): 281 – 289. (In Thai).