

การพัฒนาโมเดลพยากรณ์ดัชนีความเครียดจากความร้อนด้วย IoT ต่อสมรรถภาพการเจริญเติบโต ของไก่เนื้อ ณ ภาณุพงศ์ อินเตอร์ ฟาร์ม

Development of an IoT-Based Heat Stress Index Predictive Model for Broiler Growth Performance at Panupong Inter Farm

ภาณุพงศ์ แสงงามเรือง* และ ณัฐฐ์ โอธนาทรัพย์

สาขาวิชาการจัดการนวัตกรรมการเทคโนโลยีดิจิทัล คณะบริหารธุรกิจ มหาวิทยาลัยเอเชียอาคเนย์
19/1 ถนนเพชรเกษม แขวงหนองค้างพลู เขตหนองแขม กรุงเทพมหานคร 10160
E-mail : s6847310007@sau.ac.th , เบอร์โทรศัพท์ : 082-989-7445

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและทดสอบประสิทธิภาพของโมเดลพยากรณ์ดัชนีความเครียดจากความร้อน (H-index และ THI) จากข้อมูลอนุกรมเวลาของเครือข่ายเซนเซอร์ Internet of Things (IoT) ภายในโรงเรือนไก่เนื้อ วิเคราะห์ความสัมพันธ์เชิงปริมาณระหว่างดัชนีความเครียดจากความร้อนกับสมรรถภาพการเจริญเติบโตของไก่เนื้อ และสังเคราะห์แนวทางการประยุกต์ใช้โมเดลพยากรณ์เป็นกลไกกระตุ้น (trigger) การทำงานของระบบระบายอากาศและระบบทำความเย็นล่วงหน้า หน่วยวิเคราะห์หลักคือข้อมูลสภาพแวดล้อมภายในโรงเรือนจากระบบ CYD1 Data Logger จำนวน 8 จุดวัด บันทึกทุก 5 นาที ตลอด 42 วัน (11 กุมภาพันธ์ – 28 มีนาคม 2569) รวม 96,768 จุดข้อมูลต่อฟาร์มเมตร โดยใช้ข้อมูลสมรรถภาพของไก่เนื้อสายพันธุ์ Ross 308 จำนวน 133,920 ตัว เป็นตัวแปรผลลัพธ์ปลายทางเพื่อยืนยันคุณค่าเชิงนวัตกรรม พัฒนาโมเดลด้วยเทคนิค Long Short-Term Memory (LSTM) เปรียบเทียบกับ ARIMA และ Persistence Model ผลการวิจัยพบว่า (1) โมเดล LSTM พยากรณ์ H-index ล่วงหน้า 15 นาทีได้แม่นยำสูงสุด ($R^2 = 0.982$, RMSE = 0.87) และยังคงประสิทธิภาพที่ดีที่ 60 นาที ($R^2 = 0.931$) ลด RMSE จาก Persistence Model ได้ร้อยละ 55 (2) โรงเรือนที่มี H-index สูงมี ADG ต่ำกว่าร้อยละ 6.6–7.8 และ FCR สูงกว่าร้อยละ 7.0–7.9 ในเพศเดียวกัน (3) H-index รายสัปดาห์มีความสัมพันธ์ทางลบกับ ADG ($r = -0.698$, $p < .01$) และโมเดลถดถอยพหุคูณอธิบายความแปรปรวนได้ร้อยละ 89.1 ทุก 1 หน่วยที่ H-index เพิ่มขึ้น ADG ลดลง 2.843 กรัม/ตัว/วัน และ (4) ผู้วิจัยเสนอ data-to-action chain 5 ขั้นตอน (Sensing–Forecasting–Triggering–Action–Outcome) พร้อมประมาณการผลตอบแทนเชิงเศรษฐกิจ 3.2–3.84 ล้านบาท/ปี ผลการวิจัยสนับสนุนการประยุกต์ใช้ IoT และโมเดลพยากรณ์เป็นเครื่องมือสนับสนุนการตัดสินใจเชิงรุกในการจัดการฟาร์มไก่เนื้อเชิงพาณิชย์

คำหลัก: ดัชนีความเครียดจากความร้อน, อินเทอร์เน็ตของสรรพสิ่ง, โมเดลพยากรณ์ LSTM, ไก่เนื้อ, ระบบสนับสนุนการตัดสินใจ

Abstract

This research aimed to (1) develop and validate IoT-based predictive models for heat stress indices (H-index and THI) from time-series sensor data in broiler houses, (2) analyze the quantitative relationship between heat stress indices and broiler growth performance, and (3) synthesize practical guidelines for applying the predictive model as a trigger mechanism for ventilation and cooling systems. The primary unit of analysis was environmental data collected from a CYD1 Data Logger network at 8 measurement points, recorded every 5 minutes over 42 days (11 February – 28 March 2026), totaling 96,768 data points per parameter. Growth performance data from 133,920 Ross 308 broilers served as downstream outcomes to validate innovation value. Predictive modeling used Long Short-Term Memory (LSTM) compared with ARIMA and Persistence Model. Results showed that (1) LSTM achieved highest accuracy at the 15-minute forecast horizon ($R^2 = 0.982$, RMSE = 0.87) and maintained strong performance at 60 minutes ($R^2 = 0.931$), reducing RMSE by approximately 55% versus Persistence Model; (2) houses with higher H-index showed 6.6–7.8% lower ADG and 7.0–7.9% higher FCR within the same sex; (3) weekly H-index was significantly negatively correlated with ADG ($r = -0.698$, $p < .01$), with a multiple regression model explaining 89.1% of the variance—each 1-unit increase in H-index reduced ADG by 2.843 g/bird/day; and (4) a five-step data-to-action chain (Sensing–Forecasting–Triggering–Action–Outcome) was proposed, with an estimated annual economic return of 3.2–3.84 million baht. The findings support the application of IoT and predictive models as proactive decision-support tools for commercial broiler farm management.

Keywords: Heat Stress Index, Internet of Things, LSTM Predictive Model, Broiler Chicken, Decision Support System

1. บทนำ

อุตสาหกรรมไก่เนื้อของประเทศไทยเป็นภาคเกษตรส่งออกที่มีความสำคัญเชิงเศรษฐกิจสูง อย่างไรก็ตาม สภาพภูมิอากาศแบบร้อนชื้นที่มีอุณหภูมิและความชื้นสัมพัทธ์สูงตลอดปี ประกอบกับแนวโน้มการเปลี่ยนแปลงสภาพภูมิอากาศตามรายงาน IPCC [1] ทำให้ภาวะความเครียดจากความร้อน (heat stress) กลายเป็นปัญหาเชิงระบบในฟาร์มไก่เนื้อเชิงพาณิชย์ ปัญหานี้ส่งผลให้อัตราการเจริญเติบโตต่อวัน (ADG) ลดลง อัตราการแลกเนื้อ (FCR) แย่ลง และอัตราการตายเพิ่มขึ้น [2] การประเมินภาวะความร้อนที่ไก่ได้รับต้องพิจารณาทั้งอุณหภูมิและความชื้นร่วมกัน ดัชนีอุณหภูมิ-ความชื้น (Temperature-Humidity Index: THI) จึงเป็นเครื่องมือ

หลักที่ใช้บูรณาการทั้งสองตัวแปรเป็นพารามิเตอร์เดียว [3] ในขณะที่ H-index เป็นดัชนีที่คำนวณและรายงานโดยระบบ CYD1 Data Logger ที่ติดตั้งในฟาร์มกรณีศึกษา การศึกษาในเขตร้อนชื้นพบว่าค่า THI เฉลี่ยตลอดรอบการเลี้ยงมักอยู่ในช่วง 80.2–85.0 ซึ่งบ่งชี้สภาวะความเครียดต่อเนื่อง [4] ช่องว่างที่สำคัญของงานวิจัยที่ผ่านมาคือ งานส่วนใหญ่ใช้ THI เป็นค่าที่คำนวณได้ ณ เวลาปัจจุบัน แต่ไม่ได้พัฒนาเป็นโมเดลพยากรณ์ล่วงหน้าที่รองรับการตัดสินใจเชิงรุก แม้ระบบควบคุมสภาพแวดล้อม เช่น พัดลมและระบบทำความเย็นแบบระเหยน้ำ จะมีความหน่วงเชิงเวลา (time lag) ในการตอบสนอง การพยากรณ์ล่วงหน้าจึงจำเป็นต่อการกระตุ้น (trigger) การทำงานของระบบก่อนที่สัตว์จะเผชิญสภาวะวิกฤต [5] งานวิจัยนี้จึงมี

จากความร้อนด้วย IoT ที่ให้ความแม่นยำในระดับปฏิบัติการ (2) วิเคราะห์ความสัมพันธ์เชิงปริมาณระหว่างดัชนีดังกล่าวกับสมรรถภาพการเจริญเติบโตของไก่เนื้อในสภาพฟาร์มจริง และ (3) สังเคราะห์ข้อเสนอเชิงนวัตกรรมเกี่ยวกับห่วงโซ่การแปลงข้อมูลเป็นการกระทำ (data-to-action chain) ที่เชื่อมการพยากรณ์กับการควบคุมสภาพแวดล้อมและผลลัพธ์ด้านการผลิต โดย หน่วยวิเคราะห์หลัก คือข้อมูลอนุกรมเวลาสภาพแวดล้อมภายในโรงเรือน ขณะที่ข้อมูลสมรรถภาพของไก่เนื้อทำหน้าที่เป็นตัวชี้วัดผลกระทบปลายทาง (downstream outcome) เพื่อยืนยันคุณค่าเชิงจัดการของระบบพยากรณ์

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ดัชนีความเครียดจากความร้อนในสัตว์ปีก

ดัชนี THI เป็นตัวบ่งชี้การความร้อนเชิงรวมที่สัตว์ได้รับ โดยสูตร NRC (1971) ที่นิยมใช้ในสัตว์ปีกเขตร้อนชื้น [6] คือ

$$THI = (1.8T + 32) - (0.55 - 0.0055 \times RH) \times (1.8T - 26) \quad (1)$$

โดยที่ T คืออุณหภูมิอากาศ (°C) และ RH คือความชื้นสัมพัทธ์ (%) งานวิจัยในไก่พื้นเมืองไทยพบว่าความถดถอยทางการเจริญเติบโตเริ่มปรากฏชัดเมื่อ THI ถึงระดับ 76 ขึ้นไป [4] และระดับ THI ≥ 80 บ่งชี้ heat stress ระดับปานกลางถึงรุนแรง

2.2 IoT และการพยากรณ์อนุกรมเวลาด้วย LSTM

สถาปัตยกรรม IoT สำหรับโรงเรือนสัตว์ปีกประกอบด้วยสามเลเยอร์ ได้แก่ perception layer (เซนเซอร์และไมโครคอนโทรลเลอร์), network layer (การสื่อสารผ่าน Wi-Fi/LoRaWAN) และ cloud/application layer (การแสดงผลแบบเรียลไทม์ [7] เมื่อผนวกกับปัญญาประดิษฐ์ระบบพัฒนาเป็น AIoT ที่รับรู้ วิเคราะห์ และตอบสนองได้อัตโนมัติ [8] Long Short-Term Memory (LSTM) เป็นสถาปัตยกรรม Recurrent Neural Network (RNN) ที่ออกแบบมาเพื่อแก้ปัญหา vanishing gradient และเรียนรู้ความสัมพันธ์ระยะยาวในข้อมูลอนุกรมเวลา หน่วย LSTM ประกอบด้วยสามประตูหลัก ได้แก่ forget gate (f),

input gate (i) และ output gate (o) ที่ควบคุมการไหลของข้อมูลเข้า-ออกจากหน่วยความจำ (cell state) ดังสมการ

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \times \tanh(C_t) \quad (5)$$

เมื่อ σ คือ sigmoid activation, x_t คือ input ณ เวลา t, h_{t-1} คือ hidden state ณ เวลาก่อนหน้า, W และ b คือ weights และ bias ที่เรียนรู้ได้ สถาปัตยกรรมนี้เหมาะสมกับข้อมูลอนุกรมเวลาสภาพแวดล้อมในโรงเรือนที่มีรูปแบบรายวัน (diurnal cycle) และความสัมพันธ์ไม่เชิงเส้นที่ซับซ้อน [5]

2.3 กรอบแนวคิดการจัดการนวัตกรรมเทคโนโลยีดิจิทัล

แบบจำลองการยอมรับเทคโนโลยี (Technology Acceptance Model: TAM) ของ Davis (1989) [9] ชี้ว่าการยอมรับเทคโนโลยีในองค์กรขึ้นกับสองปัจจัย ได้แก่ perceived usefulness และ perceived ease of use ซึ่งเป็นกรอบที่เหมาะสมในการประเมินความพร้อมของระบบพยากรณ์ IoT สำหรับการนำไปใช้จริงในฟาร์มเชิงพาณิชย์ ในขณะที่แนวคิดการจัดการนวัตกรรมเชิงระบบเน้นการเปลี่ยนผ่านจากการเฝ้าระวัง (monitoring) ไปสู่การควบคุมเชิงคาดการณ์ (predictive control) ซึ่งเป็นหัวใจของการสร้างคุณค่าบนฐานข้อมูล [5]

เพื่อเชื่อมต่อระหว่างผลการพยากรณ์เชิงเทคนิคกับคุณค่าเชิงจัดการอย่างเป็นระบบ ผู้วิจัยใช้กรอบ AIM (Awareness–Implementation–Measurement) เป็นโครงเชื่อมโยงห่วงโซ่นวัตกรรม กรอบนี้แบ่งกระบวนการสร้างคุณค่าจากเทคโนโลยีดิจิทัลเป็นสามขั้น ได้แก่ (1) Awareness — การรับรู้ปัญหาและศักยภาพของเทคโนโลยีผ่านข้อมูลเชิงประจักษ์ (เช่น การตรวจวัดและพยากรณ์ ดัชนี ความเครียดด้วย IoT) (2) Implementation — การแปลงข้อมูลเป็นการกระทำเชิงปฏิบัติ (เช่น การตั้งเกณฑ์ปฏิบัติการเพื่อ trigger ระบบระบายอากาศ) และ (3) Measurement — การวัดผลลัพธ์ทั้งเชิงผลผลิต (ADG, FCR, Livability) และเชิง

เศรษฐกิจ (มูลค่าเพิ่ม/ปี) เพื่อยืนยันคุณค่าและการคืนทุน
กรอบ AIM ทำงานคู่กับ TAM โดย AIM อธิบาย "เส้นทาง
สร้างคุณค่า" ขณะที่ TAM อธิบาย "เงื่อนไขการยอมรับ"
ของผู้ใช้ปลายทาง

3. วิธีดำเนินการวิจัย

3.1 หน่วยวิเคราะห์และแหล่งข้อมูล

งานวิจัยนี้เป็นการวิจัยเชิงปริมาณภายใต้กรอบการศึกษา
ย้อนหลัง (retrospective study) จากข้อมูลจริงของภานุ
พงศ์ อินเตอร์ ฟาร์ม รุ่น 1-69 PIF2 หน่วยวิเคราะห์หลัก
คือข้อมูลสภาพแวดล้อมภายในโรงเรือน ระดับเวลา
(time-step unit) โดยเก็บจากระบบ CYD1 Data Logger
จำนวน 8 จุดวัด (4 โรงเรือน $\times$ 2 จุด) ที่บันทึกอุณหภูมิ
ความชื้นสัมพัทธ์ และ H-index ทุก 5 นาที ตลอด 42 วัน
รวมประมาณ 96,768 จุดข้อมูลต่อฟาร์มเดอร์ ซึ่งสะท้อน
วัตถุประสงค์หลักของงานวิจัยที่มุ่งพยากรณ์ตัวแปร
สภาพแวดล้อม ไม่ใช่ตัวแปรทางชีวภาพของสัตว์


หน่วยวิเคราะห์รองคือข้อมูลสมรรถภาพการผลิต
ระดับสัปดาห์-โรงเรือน (week-house unit) จำนวน 4
โรงเรือน $\times$ 6 สัปดาห์ = 24 จุดข้อมูล ซึ่งใช้ประกอบการ
ทดสอบว่า ดัชนีที่พยากรณ์ได้มีความสัมพันธ์กับผลลัพธ์
ปลายทางของการผลิต (ADG, FCR, Livability) อย่างมี
นัยสำคัญหรือไม่ กลุ่มตัวอย่างไก่เนื้อคือสายพันธุ์ Ross
308 ของ Thai Foods Group (TFG) จำนวน 133,920
ตัว เลี้ยงในโรงเรือนระบบปิดที่มีระบบทำความเย็นแบบ
ระเหยน้ำ (evaporative cooling system) ระยะเวลา
42 วัน (11 กุมภาพันธ์ – 28 มีนาคม 2569)

3.2 การพัฒนาโมเดลพยากรณ์

การพัฒนาโมเดลพยากรณ์ใช้กรอบ time-series
forecasting โดยกำหนดช่วงเวลานำการพยากรณ์
(forecast horizon) ที่สอดคล้องกับเวลาตอบสนองของ
ระบบระบายอากาศและระบบทำความเย็น ได้แก่ 15, 30
และ 60 นาที การแบ่งชุดข้อมูลใช้วิธี time-based split
(ฝึก 70%, ทดสอบ 30%) ร่วมกับ rolling-origin cross-
validation เพื่อหลีกเลี่ยง data leakage ตามแนวทาง
ของ Hewamalage et al. [10] feature engineering

ประกอบด้วย lag features (5–120 นาที), rolling
statistics (15, 30, 60 นาที) และ time features (hour
of day, day of age)

โมเดลที่ทดสอบประกอบด้วย 3 กลุ่มหลัก ได้แก่
(1) Persistence Model เป็น baseline (2) ARIMA
(1,1,1) เป็นโมเดลเชิงสถิติ และ (3) LSTM เป็นโมเดลเชิง
ลึก สถาปัตยกรรม LSTM ที่ใช้แสดงในรูปที่ 1
ประกอบด้วย input layer ที่รับ lag features, LSTM
layer 64 units พร้อม dropout 0.2, fully connected
layer และ output layer ที่ทำนาย H-index ล่วงหน้า



รูปที่ 1 สถาปัตยกรรม LSTM สำหรับพยากรณ์ H-index
ล่วงหน้า k นาที

3.3 การวิเคราะห์ความสัมพันธ์กับสมรรถภาพการผลิต

ใช้การวิเคราะห์ Pearson correlation ทั้งแบบ
zero-order และ partial correlation (ควบคุมสัปดาห์
การเลี้ยง) การวิเคราะห์การถดถอยพหุคูณ (multiple
regression) โดยมี ADG รายสัปดาห์เป็นตัวแปรตาม H-
index เป็นตัวแปรอิสระหลัก พร้อมควบคุมตัวแปรเพศ
และสัปดาห์ และการวิเคราะห์ Piecewise Regression
เพื่อหาจุดเปลี่ยน (threshold) ของความสัมพันธ์ ตัวชี้วัด

ประสิทธิภาพโมเดลพยากรณ์ประกอบด้วย MAE, RMSE, R^2 และ Mean Absolute Scaled Error (MASE) [10] กำหนดระดับนัยสำคัญ $\alpha = .05$

4. ผลการวิจัยและอภิปรายผล

4.1 ประสิทธิภาพของโมเดลพยากรณ์

ระบบ CYD1 Data Logger บันทึกข้อมูลสภาพแวดล้อมได้ครบถ้วนเฉลี่ยร้อยละ 91.35 ของข้อมูลที่คาดหวัง (96,813 จาก 105,984 records) ซึ่งอยู่ในเกณฑ์ที่ยอมรับได้สำหรับการวิเคราะห์ข้อมูลอนุกรมเวลา ผลการทดสอบประสิทธิภาพของโมเดลพยากรณ์ H-index ที่ช่วงเวลาต่างกัน แสดงในตารางที่ 1

ตารางที่ 1 ประสิทธิภาพของโมเดลพยากรณ์ H-index ที่ forecast horizon ต่างกัน


Horizon	Model	RMSE	MAE	R^2
15 นาที	Persistence	1.92	1.45	0.724
15 นาที	ARIMA	1.28	0.96	0.876
15 นาที	LSTM	0.87	0.64	0.982
30 นาที	Persistence	2.63	1.98	0.612
30 นาที	ARIMA	1.76	1.32	0.802
30 นาที	LSTM	1.43	1.08	0.963
60 นาที	Persistence	4.85	3.67	0.421
60 นาที	ARIMA	2.94	2.21	0.685
60 นาที	LSTM	2.18	1.64	0.931

หมายเหตุ: แบ่งข้อมูลฝึก 70% และทดสอบ 30% ตามเรียงลำดับเวลา (time-based split) ใช้ rolling-origin cross-validation เพื่อป้องกัน data leakage

จากตารางที่ 1 โมเดล LSTM มีประสิทธิภาพสูงกว่า ARIMA และ Persistence Model ในทุกช่วงเวลานำ โดยที่ horizon 15 นาที LSTM ลด RMSE จาก Persistence ได้ร้อยละ 54.7 และยังคงประสิทธิภาพดี ($R^2 = 0.931$) แม้ขยายไปถึง 60 นาที ผลดังกล่าว

สอดคล้องกับงานของ Zheng et al. (2025) [5] ที่ยืนยันว่า deep learning เหนือกว่าวิธีเชิงสถิติในการพยากรณ์อนุกรมเวลาสภาพแวดล้อมโรงเรือน เนื่องจาก gating mechanism ของ LSTM สามารถเรียนรู้ทั้งรูปแบบรายวันและความสัมพันธ์ไม่เชิงเส้นที่ซับซ้อน ขณะที่ ARIMA เป็นโมเดลเชิงเส้นจับความสัมพันธ์ดังกล่าวได้ไม่สมบูรณ์


เพื่อให้เห็นภาพรูปแบบของข้อมูลที่น่ามาใช้ในการพยากรณ์ รูปที่ 2 แสดงตัวอย่างอนุกรมเวลาของ H-index รายวัน (24 ชั่วโมง) จากโรงเรือนทั้ง 4 หลัง พบรูปแบบรายวัน (diurnal cycle) ที่ชัดเจน โดยค่าต่ำในช่วงกลางคืน-เช้ามืด เพิ่มขึ้นจนถึงจุดสูงสุดประมาณ 13.00–15.00 น. และลดลงในช่วงเย็น-ค่ำ ซึ่งแสดงว่าโรงเรือนเข้าสู่สภาวะเหนือเกณฑ์ THI = 79.5 ในช่วงเวลากลางวันเป็นประจำ รูปแบบดังกล่าวเป็นเหตุผลเชิงสถาปัตยกรรมที่สนับสนุนการเลือกใช้ LSTM ซึ่งเหมาะสมกับการเรียนรู้รูปแบบเชิงเวลาแบบเป็นคาบ (periodic) มากกว่าโมเดลเชิงสถิติเชิงเส้น



รูปที่ 2 อนุกรมเวลาของ H-index รายวันใน 4 โรงเรือนเปรียบเทียบกับเกณฑ์ปฏิบัติการ THI = 79.5

เพื่อยืนยันคุณภาพการพยากรณ์เชิงทัศนภาพ (visual diagnostics) นอกเหนือจากตัวเลขในตารางที่ 1 ผู้วิจัยได้สร้างกราฟกระจาย (scatter plot) ระหว่างค่าพยากรณ์ของโมเดล LSTM กับค่าจริงของ H-index ที่ horizon 15 นาที ($n = 600$ จุดสุ่มจากชุดทดสอบ) ดังแสดงในรูปที่ 3 จุดข้อมูลกระจายตัวอยู่ใกล้เส้น $y = x$ อย่างสม่ำเสมอตลอดช่วงค่าที่สังเกตได้ (70–88) ไม่พบความเอนเอียงเชิง


ระบบ (systematic bias) ทั้งในย่านค่าต่ำและย่านค่าสูง สอดคล้องกับค่า $R^2 = 0.982$ และ $RMSE = 0.87$ ที่รายงาน ลักษณะการกระจายตัวที่สมมาตรนี้เป็นหลักฐานสนับสนุนว่าโมเดลสามารถใช้เป็นกลไกแจ้งเตือนล่วงหน้าได้อย่างน่าเชื่อถือทั้งในสภาวะปกติและสภาวะวิกฤต



รูปที่ 3 กราฟเปรียบเทียบค่าพยากรณ์ของโมเดล LSTM กับค่าจริงของ H-index ที่ horizon 15 นาที

4.1.1 การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance Analysis)

เพื่อตอบประเด็นเรื่องความสามารถในการตีความของโมเดล (model interpretability) ซึ่งเป็นข้อกังวลที่พบบ่อยเมื่อใช้โมเดลกล่องดำ (black-box) เช่น LSTM ในงานวิจัยเชิงประยุกต์ ผู้วิจัยได้คำนวณค่า SHAP (SHapley Additive exPlanations) เพื่อจัดลำดับความสำคัญของตัวแปรนำเข้า (input features) ที่มีต่อค่าพยากรณ์ H-index ผลการจัดอันดับ 10 ตัวแปรที่มี mean |SHAP value| สูงสุด แสดงในรูปที่ 4 พบว่า H-index ค่าล่าสุดในอดีต (lag 5–10 นาที) เป็นตัวแปรนำเข้าที่สำคัญที่สุด รองลงมาคือ อุณหภูมิ (lag 5 นาที) และพีเอเจอร์เชิงเวลา (hour of day) ในรูป sin/cos encoding ในขณะที่ค่าสถิติเคลื่อนที่ (rolling statistics) ที่ช่วง 15 และ 60 นาที ความชื้นสัมพัทธ์ และอายุของไก่ (day of age) มีบทบาทรอง



รูปที่ 4 การจัดลำดับความสำคัญของตัวแปรนำเข้าด้วยค่า SHAP (Top-10 features)

ผลการวิเคราะห์ Feature Importance นี้สนับสนุนความน่าเชื่อถือของโมเดลในเชิงปฏิบัติด้วยเหตุผลสามประการ ประการแรก ตัวแปรที่โมเดลเลือกใช้ สอดคล้องกับความรู้เชิงประจักษ์ทางสรีรวิทยาสัตว์ปีก (domain knowledge) คือ heat stress เป็นปรากฏการณ์ที่มีความต่อเนื่องเชิงเวลาสูง (high temporal autocorrelation) และเป็นผลรวมจากอุณหภูมิ ความชื้น และเวลาในรอบวัน ประการที่สอง ความสำคัญของพีเอเจอร์ lag ระยะสั้น (5–10 นาที) ยืนยันว่าระบบ CYD1 Data Logger ที่บันทึกทุก 5 นาที มี granularity ที่เพียงพอต่อการพยากรณ์ และประการที่สาม การที่ตัวแปร hour of day ติดอันดับสูงสะท้อนว่าโมเดลเรียนรู้รูปแบบ diurnal cycle ได้อย่างถูกต้อง การวิเคราะห์นี้ช่วยลดข้อกังวลเรื่อง black-box และเพิ่ม perceived usefulness ตามกรอบ TAM โดยทำให้ผู้จัดการฟาร์มเห็นว่าการตัดสินใจของโมเดลมีฐานเหตุผลที่ตรวจสอบได้

4.2 ความสัมพันธ์ระหว่าง H-index กับสมรรถภาพการผลิต

ผลการวิเคราะห์ Pearson correlation และ multiple regression ระหว่าง H-index รายสัปดาห์กับ ADG รายสัปดาห์แสดงในตารางที่ 2 พบว่า H-index มีความสัมพันธ์ทางลบกับ ADG อย่างมีนัยสำคัญทางสถิติ ($r = -0.698$, $p < .01$) ความสัมพันธ์ทางบวกกับ FCR ($r = 0.611$, $p < .01$) และทางลบกับ Livability ($r = -0.463$, $p < .05$) โดยโมเดลถดถอยพหุคูณที่มี H-index, เพศ และสัปดาห์เป็นตัวพยากรณ์ สามารถอธิบายความแปรปรวน

$p < .001$) สัมประสิทธิ์การถดถอยของ H-index เท่ากับ -2.843 ($p < .001$) ซึ่งหมายความว่าทุก 1 หน่วยที่ H-index เพิ่มขึ้น ADG ลดลง 2.843 กรัม/ตัว/วัน เมื่อควบคุมเพศและสัปดาห์

ตารางที่ 2 ความสัมพันธ์ระหว่าง H-index รายสัปดาห์กับ ตัวชี้วัดการผลิต

ตัวแปรผลลัพธ์	r	p
ADG (g/ตัว/วัน)	-0.698	< .01**
FCR สะสม	+0.611	< .01**
Livability (%)	-0.463	< .05*
น้ำหนักสิ้นรุ่น	-0.521	< .01**


หมายเหตุ: $n = 24$ (4 โรงเรือน $\times$ 6 สัปดาห์); * $p < .05$, ** $p < .01$

การวิเคราะห์ Piecewise Regression ด้วย ข้อมูลรายวัน ($n = 160$) พบจุดเปลี่ยน (breakpoint) ที่ $THI = 79.5$ โดยที่ THI ต่ำกว่าจุดเปลี่ยน ความสัมพันธ์กับ ADG ไม่มีนัยสำคัญ ($slope = -0.255$, $p = .884$) แต่เมื่อ THI สูงกว่า 79.5 ทุก 1 หน่วยที่เพิ่มขึ้นส่งผลให้ ADG ลดลง 2.826 กรัม/ตัว/วัน อย่างมีนัยสำคัญสูง ($p = .002$) จุดเปลี่ยนนี้สามารถใช้เป็น operational threshold สำหรับระบบแจ้งเตือนในฟาร์มได้โดยตรง ผลการวิจัย สอดคล้องกับ Boonkum et al. [4] ที่รายงานความ ถดถอยทางการเจริญเติบโตในไก่พื้นเมืองไทยเริ่มชัดเจน เมื่อ THI ถึงระดับ 76 ขึ้นไป และ Dedousi et al. (2023) [11] ที่พบว่า THI เฉลี่ย 80.2–85.0 บ่งชี้สภาวะ heat stress ต่อเนื่อง

4.3 ห่วงโซ่การแปลงข้อมูลเป็นการกระทำ (Data-to-Action Chain)

ประเด็นสำคัญของงานวิจัยนี้ไม่ได้จบที่ความ แม่นยำของโมเดล แต่อยู่ที่คำถามว่า "เมื่อพยากรณ์ได้แล้ว ผลที่ได้จะ trigger อะไรต่อ" ผู้วิจัยจึงสังเคราะห์ข้อเสนอ

เป็น data-to-action chain 5 ขั้นที่เชื่อมการพยากรณ์กับ ผลลัพธ์ด้านการผลิต ดังแสดงในรูปที่ 5



รูปที่ 5 ห่วงโซ่การแปลงข้อมูลเป็นการกระทำ (data-to-action chain) 5 ขั้น

กลไกเชิงเหตุผลของห่วงโซ่นี้อธิบายได้ดังนี้ ระบบ IoT รับรู้สภาพแวดล้อมต่อเนื่อง (ขั้นที่ 1) โมเดล LSTM พยากรณ์ H-index ล่วงหน้าด้วย $R^2 > 0.93$ (ขั้นที่ 2) เมื่อ ค่าพยากรณ์เกินเกณฑ์ $THI = 79.5$ (จุดเปลี่ยนจาก Piecewise Regression) ระบบส่งสัญญาณเตือน (ขั้นที่ 3) ผู้จัดการฟาร์มหรือระบบอัตโนมัติเพิ่มความเร็วพัดลมและ เปิดระบบทำความเย็น (ขั้นที่ 4) ส่งผลให้ H-index จริง ลดลงและตามสมการถดถอยที่พัฒนาได้ ทุก 1 หน่วย H-index ที่ลดได้จะทำให้ ADG เพิ่มขึ้น 2.843 กรัม/ตัว/วัน พร้อมผลเชิงบวกต่อ FCR และ Livability (ขั้นที่ 5) ห่วงโซ่ ทั้ง 5 ขั้นสะท้อน perceived usefulness ตามกรอบ TAM [9] และเป็นตัวอย่างรูปธรรมของการยกระดับการจัดการจาก reactive ไปสู่ proactive ตามแนวคิดการจัดการนวัตกรรมเชิงระบบ

4.4 การวิเคราะห์ต้นทุน-ผลตอบแทน (Cost-Benefit Analysis)

เพื่อตอบข้อเสนอนี้ของกรรมการที่ปรึกษา เรื่องการเชื่อมโยงผลวิจัยเข้ากับคุณค่าเชิงจัดการ ผู้วิจัย ประเมินการผลตอบแทนจากการนำระบบไปใช้จริง โดยใช้ข้อมูลจริงของรอบการเลี้ยงที่ศึกษา ได้แก่ จำนวนไก่ส่ง โรงเชือด 128,586 ตัว น้ำหนักเฉลี่ย 3.138 กก./ตัว ราคา ขาย 41.75 บาท/กก. และผลต่าง BW ระหว่างเล้า H-index สูงและต่ำ (ในเพศเดียวกัน) คือร้อยละ 7.6

หากสมมติแบบอนุรักษ์นิยมว่าระบบพยากรณ์ช่วยลด ช่องว่างได้ร้อยละ 50 (เหลือร้อยละ 3.8) จะได้น้ำหนักเพิ่ม $128,586 \times 3.138 \times 3.8\% \approx 15,332$ กก./รอบ คิดเป็น มูลค่าเพิ่ม 640,110 บาท/รอบการเลี้ยง เมื่อฟาร์มเลี้ยงได้ 5-6 รอบ/ปี ผลตอบแทนสะสมประมาณ 3.2-3.84 ล้านบาท/ปี ทั้งนี้ยังไม่รวมผลประโยชน์จาก FCR ที่ลดลง (ประหยัดค่าอาหาร) และการเพิ่มขึ้นของ Livability (ลด การสูญเสียจำนวนตัว) ซึ่งเป็นผลพลอยได้เพิ่มเติม ต้นทุน การพัฒนาและบำรุงรักษาระบบใช้โครงสร้างพื้นฐาน CYD1 ที่มีอยู่เดิม ไม่ต้องลงทุนเซนเซอร์ใหม่ ระยะเวลาคืน ทุนจึงประเมินได้ที่ 1-2 รอบการเลี้ยง

เมื่อเชื่อมโยงผลการวิจัยเข้ากับกรอบ AIM ตามที่นำเสนอ ในหัวข้อ 2.3 จะเห็นภาพรวมของกระบวนการสร้างคุณค่า จากนวัตกรรมได้อย่างเป็นระบบ ดังนี้ ขั้น Awareness ได้รับการสนับสนุนจากการสาธิตว่าโรงเรือนเข้าสู่สภาวะ เหนือเกณฑ์ THI = 79.5 ในช่วงกลางวันเป็นประจำ (รูปที่ 2) และความสัมพันธ์ทางลบที่มีนัยสำคัญสูงระหว่าง H-index กับ ADG ($r = -0.698$) ซึ่งทำให้ปัญหา "มองเห็น" และวัดได้ในเชิงปริมาณ ขั้น Implementation ได้รับการ สนับสนุนจากความแม่นยำของโมเดล LSTM ($R^2 = 0.982$) และห่วงโซ่ data-to-action 5 ขั้น ซึ่งแปลง สัญญาณพยากรณ์เป็นการกระทำได้อย่างเป็นรูปธรรมโดย ใช้โครงสร้างพื้นฐาน CYD1 ที่มีอยู่เดิม และขั้น Measurement สะท้อนผ่านมูลค่าเพิ่มที่ประมาณการได้ 640,110 บาท/รอบ (3.2-3.84 ล้านบาท/ปี) ระยะเวลา คืนทุน 1-2 รอบการเลี้ยง และตัวชี้วัดปลายทาง (ADG, FCR, Livability) ที่ตรวจสอบได้ การเชื่อมโยงครบสามขั้น

นี้ทำให้นวัตกรรมที่เสนอมีคุณค่าเชิงจัดการที่วัดได้และ ตรวจสอบได้ ไม่ใช่เพียงข้อเสนอเชิงเทคนิค

4.5 ข้อจำกัดของการวิจัย

งานวิจัยนี้มีข้อจำกัดสำคัญสามประการ ประการ แรก จำนวนหน่วยวิเคราะห์ระดับสัปดาห์-โรงเรือน ($n = 24$) ค่อนข้างต่ำสำหรับการถดถอย ซึ่งอาจจำกัดอำนาจ ทางสถิติในการตรวจจับความสัมพันธ์ที่ซับซ้อนกว่าเชิงเส้น ผู้วิจัยได้ลดข้อจำกัดนี้บางส่วนด้วยการใช้ข้อมูลรายวัน ($n = 160$) ใน Piecewise Regression ประกอบการวิเคราะห์ ประการที่สอง การศึกษาครอบคลุมเพียง 1 รอบการเลี้ยง (รุ่น 1-69 PIF2) ในช่วงฤดูร้อนตอนต้น ทำให้ generalizability ข้ามฤดูกาลยังจำกัด การขยายการเก็บ ข้อมูลข้ามรุ่นและข้ามฤดูกาลเป็นข้อเสนอสำหรับการวิจัย ต่อเนื่อง โดยเฉพาะอย่างยิ่งการประเมินความสามารถใน การอ้างอิงทั่วไป (external validity) ของโมเดลต่อบริบท อื่น ๆ มีประเด็นที่ควรพิจารณาในเชิงระยะรั่วสาม ประการ คือ (ก) โมเดลถูกฝึกจากฟาร์มแห่งเดียวที่ใช้สาย พันธุ์ Ross 308 ระบบโรงเรือนปิดที่มี evaporative cooling และระบบ CYD1 Data Logger เฉพาะรุ่น ค่า พยากรณ์เชิงตัวเลขอาจไม่สามารถถ่ายโอนตรง ๆ ไปยัง ฟาร์มที่ใช้สายพันธุ์อื่น โครงสร้างโรงเรือนต่างกัน หรือ เซนเซอร์คนละยี่ห้อ (ข) สมการถดถอย $ADG = f(H\text{-index})$ ที่ได้รับมาเฉพาะกับเงื่อนไขการจัดการของฟาร์ม กรณีศึกษา (อาหาร โปรแกรมแสง ความหนาแน่น) จึงควร นำไปใช้เป็นกรอบเชิงเหตุผล (mechanistic template) มากกว่าค่าคงที่สากล และ (ค) เกณฑ์ปฏิบัติการ THI = 79.5 จาก piecewise regression ก็ควรได้รับการสอบ เเทียบใหม่ (re-calibration) เมื่อนำไปใช้ในฟาร์มอื่น แนวทางที่เหมาะสมคือใช้สถาปัตยกรรมและขั้นตอนวิธี (pipeline) ของงานวิจัยนี้เป็น "แม่แบบ" แล้วใช้ transfer learning หรือ fine-tuning ด้วยข้อมูลของฟาร์มเป้าหมาย อย่างน้อย 1 รอบการเลี้ยง ก่อนนำไปใช้จริง และ ประการ ที่สาม การประมาณการต้นทุน-ผลตอบแทนเป็นการ คำนวณแบบอนุรักษ์นิยม มูลค่าจริงอาจสูงกว่าหรือต่ำกว่า นี้ขึ้นกับคุณภาพของระบบระบายอากาศเดิมและความเร็ว ในการตอบสนองของผู้ปฏิบัติงาน

5. สรุปผลการวิจัย

งานวิจัยนี้พัฒนาโมเดลพยากรณ์ดัชนีความเครียดจากความร้อนด้วย IoT บนพื้นฐานของข้อมูลอนุกรมเวลาจากระบบ CYD1 Data Logger 8 จุดวัดภายในโรงเรือนไก่เนื้อจริง ผลพบว่า (1) LSTM พยากรณ์ H-index ล่วงหน้า 15 นาทีได้แม่นยำสูงสุด ($R^2 = 0.982$) และยังคงประสิทธิภาพที่ 60 นาที ($R^2 = 0.931$) ลด RMSE จาก Persistence ได้ร้อยละ 55 (2) H-index มีความสัมพันธ์ทางลบกับ ADG ($r = -0.698$, $p < .01$) โมเดลถดถอยอธิบายได้ร้อยละ 89.1 ทุก 1 หน่วยที่ H-index เพิ่มขึ้น ADG ลดลง 2.843 กรัม/ตัว/วัน (3) จุดเปลี่ยนที่ THI = 79.5 ใช้เป็น operational threshold ได้โดยตรง และ (4) ท่วงโซ่ data-to-action 5 ชั้นเชื่อมโยงการพยากรณ์กับการควบคุมโรงเรือนและผลผลิต ให้ผลตอบแทนเชิงเศรษฐกิจประมาณ 3.2–3.84 ล้านบาท/ปี คุณค่าเชิงนวัตกรรมของงานวิจัยนี้คือการสร้างระบบที่ยกระดับการจัดการฟาร์มจากการตรวจวัด (monitoring) สู่การควบคุมเชิงคาดการณ์ (predictive control) โดยใช้โครงสร้างพื้นฐาน IoT เดิมของฟาร์มโดยไม่ต้องลงทุนเพิ่มเติม

6. กิตติกรรมประกาศ

ผู้วิจัยขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. ณัฏฐ์ โอธนาทรัพย์ อาจารย์ที่ปรึกษา ที่ให้คำแนะนำและชี้แนะแนวทางตลอดงานวิจัย และขอขอบพระคุณ ภาณุพงศ์ อินเตอร์ ฟาร์ม ที่ได้เปิดโอกาสให้ใช้ข้อมูลการเลี้ยงและระบบ CYD1 Data Logger ซึ่งเป็นรากฐานของการวิเคราะห์ในงานวิจัยนี้

7. เอกสารอ้างอิง

- [1] IPCC (2021). Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, Cambridge University Press.
- [2] Kim, H.R., Seong, P., Seol, K.-H., Park, J.-E., Kim, H., Park, W., Cho, J.H. and Lee, S.D. (2024). Effects of Heat Stress on Growth Performance, Physiological Responses, and Carcass Traits in Broilers, *Journal of Thermal Biology*, Vol. 124, 103971.
- [3] Dedousi, A., Kritsa, M.-Z. and Sossidou, E.N. (2023). Thermal Comfort, Growth Performance and Welfare of Olive Pulp Fed Broilers During Hot Season, *Sustainability*, Vol. 15 (14), 10932.
- [4] Boonkum, W., Duangjinda, M., Kananub, S., Chankitisakul, V. and Kaewkanha, T. (2024). Heat Stress Effects on the Genetics of Growth Traits in Thai Native Chickens (Pradu Hang dum), *Animal Bioscience*, Vol. 37 (1), pp. 16–27.
- [5] Zheng, P., Zhang, W., Gao, B., Ma, Y. and Chen, C. (2025). Multi-Step Apparent Temperature Prediction in Broiler Houses Using a Hybrid SE-TCN-Transformer Model with Kalman Filtering, *Sensors*, Vol. 25 (19), 6124.
- [6] National Research Council (1971). A Guide to Environmental Research on Animals, National Academy of Sciences, Washington D.C.
- [7] Chang, Y.-S. and Tu, L.-Y. (2023). Use of IoT Sensors to Build an Intelligent Monitoring and Control System for Poultry House Environment, *Sensors and Materials*, Vol. 35 (12), pp. 3997–4012.
- [8] Awoke, T.D., Tedila, H.M. and Birhanu, G.A. (2024). The Role of Artificial Intelligence and Internet of Things in Improving Poultry Farm Management: A Systematic Review, *Heliyon*, Vol. 10 (8), e29467.

[9] Davis, F.D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology, MIS Quarterly, Vol. 13 (3), pp. 319–340.

[10] Hewamalage, H., Ackermann, K. and Bergmeir, C. (2023). Forecast Evaluation for Data Scientists: Common Pitfalls and Best Practices, Data Mining and Knowledge Discovery, Vol. 37 (2), pp. 788–832.

[11] Mangan, M. and Siwek, M. (2024). Strategies to Combat Heat Stress in Poultry Production — A Review, Journal of Animal Physiology and Animal Nutrition, Vol. 108 (3), pp. 576–595.

ประวัติผู้เขียนบทความ



นายภาณุพงศ์ แสงงามเรือง
สำเร็จการศึกษาระดับปริญญาตรีวิทยาศาสตร์บัณฑิต
สาขาวิทยาศาสตร์และเทคโนโลยีการอาหาร
ปัจจุบันกำลังศึกษาระดับปริญญาโท หลักสูตรวิทยาศา
สตรมหาบัณฑิต สาขาวิชาการจัดการนวัตกรรม
เทคโนโลยีดิจิทัล มหาวิทยาลัยเอเชียอาคเนย์
ดำรงตำแหน่งกรรมการบริษัท บริษัท ภาณุพงศ์ อินเตอร์
ฟาร์ม จำกัด ตำบลห้วยกระเจา อำเภอยางชุมน้อย
จังหวัดกาฬสินธุ์

งานวิจัยที่สนใจ: การประยุกต์ใช้เทคโนโลยี
ดิจิทัลและ IoT ในการจัดการฟาร์มสัตว์ปีก, Machine
Learning สำหรับการเกษตรอัจฉริยะ (Smart Farming),
การพัฒนาระบบสนับสนุนการตัดสินใจเชิงรุกสำหรับปศุ

สัตว์, และการจัดการคุณภาพอากาศและสวัสดิภาพสัตว์ใน
โรงเรือนปิด



Otanasap, Nuth Ph.D., Assistant Professor,
Department of Computer Engineering,
and Director of Management of Digital Technology
Innovation Master Program
Faculty of Engineering,
Southeast Asia University, Bangkok, Thailand.

[Expertise: Neural and fuzzy techniques in
nonlinear signal processing and noise processing].

Education:

- * B.Sc. in Computer Science
- * M.Sc. in Electronic Business
- * Ph.D. in Management of Information Technology
- ISO/IEC 29110 and ISO/IEC 15504 (33000) Consult,
Auditor, and Lecture
- Certified NETPIE Trainer
- LoRaWAN Trainer
- AIX System Administrator
- Software Process Improvement (CMMI) Trainer
- AI Research Methodology