

การตรวจจับพฤติกรรมการกินของสุกรแบบอัตโนมัติ
(Automatic detection eating behavior of pigs)

สุริยา แพนลา
Suriya Panla

ภาควิชาสัตวศาสตร์ คณะเกษตรศาสตร์ มหาวิทยาลัยอุบลราชธานี

บทคัดย่อ

สัมมนาฉบับนี้มีวัตถุประสงค์เพื่อศึกษาระบบอัตโนมัติในการตรวจจับพฤติกรรมการกินอาหารของสุกร โดยทำการรวบรวมและศึกษาเอกสารทางวิชาการจำนวน 3 ฉบับตั้งแต่ปี ค.ศ. 2018-2020 โดยศึกษาวิธีการ Convolutional neural networks (CNN) หรือโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ใช้วิเคราะห์ภาพถ่าย จากการทดลองทั้ง 3 งานพบว่า การตรวจจับพฤติกรรมการกินของสุกรโดยใช้วิธี CNN โมเดล GoogLeNet มีความแม่นยำถึง 99.4% โมเดล Xception + LSTM มีความแม่นยำ 98.4% และโมเดล Faster R-CNN ค่าความแม่นยำ 86.93% ดังนั้นสรุปได้ว่าการใช้เทคโนโลยีการตรวจสอบพฤติกรรมการกินอาหารของสุกรด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันทั้ง 3 โมเดลมีประสิทธิภาพค่อนข้างสูงจึงมีแนวโน้มที่จะสามารถนำมาใช้งานได้ และการใช้งานระบบอัตโนมัติจำเป็นต้องอาศัยเงินลงทุนจึงเหมาะกับฟาร์มขนาดใหญ่

คำสำคัญ พฤติกรรมการกิน, สุกร, แบบอัตโนมัติ

บทนำ

การเลี้ยงสุกรปัจจุบันมุ่งเน้นไปที่ผลผลิตสูงสุดของสุกรแต่ละตัว ดังนั้นการให้อาหารและพฤติกรรมการกินของสุกรจึงเป็นสิ่งสำคัญ เนื่องจากการกินอาหารของสุกรสัมพันธ์กับผลผลิตที่ตามมาโดยตรง การติดตามพฤติกรรมของสุกรแต่ละตัวต้องอาศัยบุคลากรจำนวนมาก ซึ่งมีค่าแรงงานที่ค่อนข้างสูงและส่งผลให้ต้นทุนการผลิตสูงขึ้นไปด้วย การให้อาหารต้องมีความเหมาะสมต่อความต้องการในแต่ละวัน เทคโนโลยีการตรวจจับพฤติกรรมการกินอาหารแบบอัตโนมัติเป็นทางเลือกหนึ่งที่จะสะดวกและรวดเร็ว (Abolghasemi et al., 2018; Alameer et al., 2016, 2020) ดังนั้นสมมติฐานนี้จึงมีวัตถุประสงค์ เพื่อศึกษาการตรวจจับพฤติกรรมการกินของสุกรแบบอัตโนมัติ

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional neural network: CNN) เป็นการเรียนรู้เชิงลึกโดยจำลองการมองเห็นของมนุษย์ในพื้นที่ย่อยของภาพ และแยกลักษณะภาพ เช่น สี ลายเส้น และการตัดกันของสี จากนั้นนำกลุ่มของพื้นที่ย่อยมาวิเคราะห์พฤติกรรม (Phongchit, 2018)

การเรียนรู้เชิงลึกโมเดลแฟสเตอร์อาร์ซีเอ็นเอ็น

Yang et al. (2018) ใช้กล้องอินฟราเรดที่มีความยาวโฟกัส 2.8 มม. เพื่อบันทึกวิดีโอ 25 เฟรมต่อวินาทีที่ขนาด 2560 × 1440 พิกเซล วิดีโอถูกจัดเก็บโดยใช้เครื่องบันทึกฮาร์ดดิสก์ ข้อมูลการทดลองมาจากคอกสุกรที่มีสุกร 4 ตัวได้รับเลือกเป็นฉากเฝ้าติดตามขนาดคอก 20 ตารางเมตร (4×5 ม.) มีจุกน้ำ 2 อันและรางให้อาหาร 1 รางสุกรได้รับอาหารวันละสองครั้งในตอนเช้าและตอนเที่ยง สุกรถูกเลี้ยงอย่างมีอิสระภายในคอกและมีน้ำดื่มตลอดเวลา กล้องถูกจัดวางอยู่ตำแหน่งกึ่งกลางของคอกและสูงจากพื้น 5 เมตรเพื่อให้ครอบคลุมทั่วทั้งคอก ใช้เวลาทำการทดลองใช้เวลาตั้งแต่วันที่ 8 กรกฎาคม 2016 ถึง 6 สิงหาคม 2016 รวม เป็น 30 วัน Figure 1 แสดงรูปการตรวจจับพฤติกรรมการกินของสุกร รูปซ้ายรูปต้นฉบับ รูปขวาคือรูปผลลัพธ์การตรวจจับพฤติกรรมการกินจากระบบ

Q. Yang et al.

Computers and Electronics in Agriculture 155 (2018) 453–460



Figure 1 Some sample frames of the video sequence.

Source: Yang et al. (2018)

การเรียนรู้เชิงลึกโมเดลเอ็กเซชันและแอลเอสทีเอ็ม

Chen et al. (2020) ได้ทำการทดลองโดยการที่นำวิดีโอจากศูนย์การสอนและวิจัยสุกรแห่งมหาวิทยาลัยแห่งรัฐมิชิแกนมาใช้ในการศึกษา โดยใช้สุกรอนุบาลเพศผู้ที่ยอายุ 26.5 ± 0.52 วันจำนวน 16 ตัว คอกอนุบาลมีขนาด 1.78×1.88 ม. และมีจุกให้น้ำและรางอาหารซึ่งมีขนาด 60.96 ซม. แบ่งเป็นช่องหัวสัตว์ขนาด 15.24 ซม. 4 ช่องกล้องวงจรปิด IR 1080p กลางแจ้ง ถูกวางไว้เหนือคอกที่มีความสูง 2.44 เมตร ใช้กล้องในการบันทึกวิดีโอแบบ RGB ที่มีความละเอียด 1180×830 พิกเซล และอัตราการถ่ายภาพ 30 เฟรมต่อวินาที เนื่องจากสุกรส่วนใหญ่นอนหลับตอนกลางคืน ดังนั้นวิดีโอจะถูกบันทึกในช่วง 09:00–17:00 น. ของแต่ละวัน วิดีโอขณะให้อาหารและไม่ให้อาหารของสุกรใช้หน่วยประมวลผลกลางคอมพิวเตอร์ Intel คอร์ i7-3.70 GH พร้อมหน่วยความจำ RAM 24 GB ที่ใช้ระบบปฏิบัติการ Microsoft Windows 10 Enterprise การ์ดจอเป็น NVIDIA GeForce RTX 2080 พร้อมหน่วยความจำ 8 GB ซอฟต์แวร์ที่ใช้สำหรับการพัฒนาอัลกอริทึมคือ Python 3.7.3 CNN และ LSTM ถูกนำมาใช้ในเฟรมเวิร์กของ Tensorflow 1.13.1 และ Keras 2.2.4 ตามลำดับ Figure 2 ภาพจากกล้องตัวที่ 1 เป็นการ Training set ภาพจากกล้องตัวที่ 2 เป็นการ Test set




Fig. 1. Allocation of the datasets of feeding and non-feeding episodes.

Figure 2 Allocation of the datasets of feeding and non-feeding episodes.

Source: Chen et al. (2020)

การเรียนรู้เชิงลึกโมเดลกูสเน็ต

Alameer et al. (2020) ได้ใช้กล้อง 2 ตัวในการดูพฤติกรรมของสุกรโดยจะติดอยู่ด้านบนของคอกและตั้งฉากกับพื้นคอก ในพื้นที่คอกขนาด 4×2.4 เมตร มีจุกน้ำ 4 หัวและรางอาหาร 4 ราง กล้องบันทึกวิดีโอการกินอาหารของสุกรที่ 25 เฟรมต่อวินาที (FPS) โดยมีความละเอียดขนาด 640×360 พิกเซล การใช้เฟรมตัวอย่างของ

การบันทึกวิดีโอ ระบุคำอธิบายประกอบแบบกำหนดเองสำหรับสุกรที่ได้กินและไม่ได้กินอาหาร (NNV) ไปยังพื้นที่ให้อาหารที่สร้างขึ้น โดยผู้ที่ได้รับการฝึกอบรมมาอย่างดี ใช้การสุ่มตัวอย่างแบบสแกนของกิจกรรมประจำวันเป็นเวลา 10 นาทีในช่วงเริ่มต้นทุกๆครึ่งชั่วโมง ตั้งแต่ 06:00 น.- 11:40 น. จากการสังเกตเน้นไปที่พฤติกรรมที่เกี่ยวข้องกับการกินอาหาร เฉพาะภาพวิดีโอรอบพื้นที่ให้อาหาร กล่าวคือ ร่างอาหารสองรางที่ติดกล้องไว้และโซนกินอาหารด้านหน้ารางน้ำ และด้านข้างของรางอาหารชั้นนอกสุด ถูกนำมาใช้สำหรับวิเคราะห์พฤติกรรม การวิเคราะห์และพื้นที่คอกที่เหลืออยู่ไม่รวมโดยปัจจัยการลดขนาดภาพที่ 4.6 ติดตาม Miller และคณะ(2019) รายงานว่าสุกรกำลังกินอาหารเมื่อมีหัวอยู่ในรางอาหาร NNV วิเคราะห์การกินอาหารเมื่อหมูเข้าไปในพื้นที่ให้อาหาร (เช่น บนพื้นสีดำหรือด้านข้างของรางอาหารชั้นนอกสุด) ด้วยเท้าสองเท้า (หนึ่งในนั้นคือเท้าหน้า) โดยไม่เคยกินอาหารเลย หลังจากการตรวจสอบแบบจำลอง คำนวณดัชนีการให้อาหารและดัชนี NNV ตามสมการ ดังนี้

$$F_i = \frac{\sum_{k=1}^N FPF}{N}$$

$$NNV_i = \frac{\sum_{k=1}^N NPF}{N}$$

Figure 3 ขั้นตอนการพัฒนา ระบบ โดยนำเข้า Training set สู่กระบวนการเรียนรู้ของเครื่องและประเมินผลระบบด้วย Test set ผลการประเมินแสดงได้ดัง Table 1




Figure 3 Examples of the image classes of pig behaviour in our dataset. The behaviours of interest were classified as feeding (i.e., a pig head in the trough), a pig performing non-nutritive visit (NNV) (i.e., a pig had two of its legs, including one front leg on the area defined by the mat under the trough) or none (i.e., a pig was not feeding or performing a NNV).

Source: Alameer et al. (2020)

Table 1 Precision rate recall of the FRPD.

	A	B	C	D	Head
Precision Rate	0.9804	1	0.8462	0.9896	0.9875
Recall Rate	1	0.9048	0.99	0.9048	0.79

Source: Yang et al. (2018)

Yang et al. (2018) พบว่าค่าความแม่นยำไม่มีความแตกต่าง กลุ่มที่มีความแม่นยำที่สุดคือกลุ่ม B, D, A, C มีค่า 1, 0.9896, 0.9804 และ 0.8462 ตามลำดับ และค่าการตรวจจับหัวสุกรอยู่ที่ 0.9875 อัตราการเรียกคืนที่มีความแม่นยำมากที่สุดคือ A, C, B, D (1, 0.99, 0.9048, 0.9048 ตามลำดับ) มีค่าการตรวจจับหัวของสุกรที่ 0.79 แต่ละกลุ่มไม่มีความแตกต่างกัน ทั้งนี้อาจมีสาเหตุมาจากการเฝ้าดูของกล้องที่ใช้ในการตรวจจับพฤติกรรมของสุกร แสดงได้ดัง Table 2

Table 2 Average classification accuracy (%) for the test data. TL (i.e., transfer learning) and no pre – training (i.e., training from scratch) correspond to the mechanisms used to train models. Our primary model with both TL and gray – scaling outperforms other proposed architecture by a large margin in all scenarios.

Time Point	Grey Scale		RGB Scale	
	TL	Scratch	TL	Scratch
Baseline	97.67±2.217	91.77±8.02	92.23±6.89	90.02±9.41
Day 4 food restriction	98.02±1.83	92.40±7.21	97.93±1.58	92.34±7.31
Day returned to ad – libitum feeding	97.15±3.35	92.32±6.00	94.20±8.65	86.25±18.12
Other batches	97.10±1.98	90.71±7.43	92.66±1.87	90.28±7.51
Sunlight exposure	96.40±2.17	93.47±3.85	94.82±2.93	90.77±4.16

Source: Alameer et al. (2020)

Alameer et al. (2020) ได้ทำการศึกษาพฤติกรรมการกินอาหารของสุกรโดยใช้กล้องตรวจจับพฤติกรรม การกินอาหารในสุกร แล้วนำภาพจากการบันทึกมาวิเคราะห์โดยป้อนภาพให้เครื่องทำการวิเคราะห์โดยมีชุดข้อมูล 2 ประเภทคือภาพที่เป็นสีขาวดำ และ ภาพที่เป็นสี RGB โดยมีเงื่อนไข 2 กรณีคือวิเคราะห์โมเดลที่มีภาพตัวอย่าง (Transfer Learning) และกรณีที่ไม่มีภาพตัวอย่างพบว่าการป้อนข้อมูลที่เป็นภาพขาวดำ การวิเคราะห์โมเดลที่เคย

เรียนรู้ภาพ(TL) มีความแม่นยำสูงกว่าโมเดลที่ไม่เคยผ่านการเรียนรู้ภาพมาก่อน เช่นเดียวกับการวิเคราะห์ภาพโดยใช้สี RGB ที่พบว่าโมเดลที่เคยเรียนรู้ภาพมีค่าสูงกว่าโมเดลที่ไม่เคยผ่านการเรียนรู้ภาพมาก่อน และเมื่อเปรียบเทียบประเภทของภาพที่ป้อนเข้าสู่ระบบการวิเคราะห์ที่พบว่า กลุ่มภาพขาวดำมีความแม่นยำสูงกว่ากลุ่มภาพ RGB ทั้งนี้อาจเป็นเพราะ การวิเคราะห์ภาพสี RGB มีลำดับขั้นตอนการวิเคราะห์ที่มากกว่า กล่าวคือต่อวิเคราะห์ภาพสีแดง สีเขียว และสีน้ำเงินก่อนที่จะประมวลผลจึงทำให้ผลการรวมค่าสีต่างๆ มีความคลาดเคลื่อนมากทำให้ความแม่นยำลดลง

Table 3 The number of true positive (TP), false negative (FN), false positive (FP) and true negative (TN) episodes and accuracy, sensitivity, specificity and precision of recognizing pig feeding by using the Xception and LSTM network and other 4 CNNs and LSTM networks in the test set

	Algorithms				
	Xception + LSTM	Inception + LSTM	ResNet50 + LSTM	VGG19 + LSTM	VGG16 + LSTM
TP	24,352	24,299	23,456	23,033	22,811
FN	304	357	1191	1623	1845
FP	1036	1768	4061	5457	5853
TN	60,708	59,976	57,683	56,287	55,891
Accuracy	98.4%	97.5%	93.9%	91.8%	91.1%
Sensitivity	98.8%	98.6%	95.2%	93.4%	92.5%
Specificity	98.3%	97.1%	93.4%	91.2%	90.5%
Precision	95.9%	93.2%	85.2%	80.8%	79.6%

Source: Chen et al. (2020)

Chen et al. (2020) ได้ทำการศึกษาพฤติกรรมการกินอาหารของสุกรโดยใช้สถาปัตยกรรม CNN หรือโครงข่ายประสาทเทียมคอนโวลูชันโดยมีลักษณะคล้ายการเรียนรู้ของประสาทมนุษย์ โดยใช้ Long short – Term memory (LSTM) รวมกับโมเดลของสถาปัตยกรรมได้แก่ Xception, Inception, Resnet, VGG19, และ VGG16 พบว่าโมเดลของ Xception มีค่าความแม่นยำสูงที่สุดเมื่อเปรียบเทียบกับ Inception, Resnet, VGG19, และ VGG16 ตามลำดับ และมีค่าการตอบสนอง ค่าความถูกต้องที่สูงกว่าตามลำดับ (Table 3)

Table 4 แสดงตารางเปรียบเทียบทั้ง 3 งานวิจัยพบว่า Alameer et al. (2020) ได้ทำการทดลองโดยใช้วิธี CNN โมเดล GoogLeNet ได้ความแม่นยำ 99.40% มีความแม่นยำมากที่สุด

Table 4 Accuracy analysis comparison

Source	Yang et al. (2018)	Chen et al. (2020)	Alameer et al. (2020)
breed	Landrace	Landrace	Landrace/Large white
number	4	16	15
method.	Faster R-CNN	Xception + LSTM	GoogLeNet
camera	Infrared network camera	Door dome security camera	RGB cameras
model	(DS-2CD3345-I, Hikvision, hangzhou, china)	(CTP-TLVA29AV, cantek plus, USA)	(Microsoft kinect for xbox one, microsoft, redmond, washington, USA)
Picture	500	278,400	34,375
Accuracy	86.93%	98.40%	99.40%

Source: Yang et al. (2018), Chen et al. (2020), Alameer et al. (2020)

สรุปผล

จากการตรวจจับพฤติกรรมการกินอาหารของสุกรทั้ง 3 งานทดลองพบว่าทุกโมเดลมีความแม่นยำที่ค่อนข้างสูง ดังนั้นสรุปได้ว่าการใช้เทคโนโลยีการตรวจสอบพฤติกรรมการกินอาหารของสุกรด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันทั้ง 3 โมเดลมีแนวโน้มที่จะสามารถนำมาใช้งานได้จริง และการใช้งานระบบอัตโนมัตินี้จำเป็นต้องอาศัยเงินลงทุนจึงเหมาะกับฟาร์มขนาดใหญ่

เอกสารอ้างอิง

- Alameer, A., Kyriazakis, I., Dalton, H.A., Miller, A.L. and Bacardit, J. 2020. “Automatic recognition of feeding and foraging behaviour in pigs using deep learning”. **Biosystems Engineering**. 197: 91-104.
- Chen, C., Zhu, W., Steibel, J., Siegford, J., Han, J. and Norton, T. 2020. “Recognition feeding behaviour of pigs and determination of feeding time”. **Computers and Electronics in Agriculture**. 176: 105642.
- Yang, Q., Xiao, D. and Lin, S. 2018. “Feeding behavior recognition for Group-housed pigs with the Faster R-CNN”. **Computers and Electronics in Agriculture**. 155: 453-460.
- Phongchit, N. 2018. Convolutional Neural Network (CNN). <https://medium.com/@natthawatphongchit/มาลองดูวิธีการคิดของ-cnn-กัน-e3f5d73eebaa>. 27 ธันวาคม.
- Miller, A.L., Dalton, H.A., Kanellos, T. and Kyriazakis, I. (2019). “How many pigs within a group need to be sick to lead to a diagnostic change in the groups behavior”. **Journal of Animal Science**. 97(5): 1956-1966.
- Abolghasemi, V., Chen, M., Alameer, A., Ferdowsi, S., Chambers, J., and Nazarpour, K. (2018). “Incoherent dictionary pair learning: Application to novel open-source database of Chinese numbers”. **IEEE Signal Processing Letters**. 25: 472-476.