

วิธีการตรวจสอบไข่มีเชื้อแบบอัตโนมัติ  
Automatic Methods for Fertile Egg Detection

กิตติ สรรพอำไพ

KITTI SAPUMPHAI

ภาควิชาสัตวศาสตร์ คณะเกษตรศาสตร์ มหาวิทยาลัยอุบลราชธานี

บทคัดย่อ

สัมนานฉบับนี้มีวัตถุประสงค์เพื่อศึกษาการตรวจสอบไข่มีเชื้อหรือไม่มีเชื้อแบบอัตโนมัติโดยการใช้เทคโนโลยีการวิเคราะห์ภาพและการประเมินผลในการจำแนกกลุ่มของไข่มีเชื้อและไม่มีเชื้อ เพื่อศึกษาวิธีการที่มีประสิทธิภาพและความแม่นยำในกระบวนการตรวจสอบได้อย่างรวดเร็วและถูกต้อง แบบจำลองการทำนายได้ถูกสร้างขึ้นจากข้อมูลชุดเรียนรู้และทำการทดสอบประสิทธิภาพด้วยข้อมูลชุดทดสอบ วิธีการตรวจสอบไข่มีเชื้อหรือไม่มีเชื้อแบบอัตโนมัติโดย A Machine Vision System ด้วยวิธีส่องไฟและประมวลผลภาพ มีความแม่นยำ 98.25% วิธีการ Ultrasound มีความแม่นยำ 86.75% และวิธีการประมวลผลภาพด้วย Deep learning มีความแม่นยำถึง 99.50% จากการทดลองแสดงให้เห็นว่าวิธีการวิเคราะห์ภาพเพื่อตรวจสอบไข่มีเชื้อหรือไม่มีเชื้อแบบอัตโนมัติสามารถนำมาประยุกต์ใช้ในอุตสาหกรรมได้

คำสำคัญ : การจำแนกประเภท โครงข่ายประสาทเทียม แมชชีนวิชัน การประมวลผลภาพ

## บทนำ

การฟักไข่ในปัจจุบันได้กลายเป็นการฟักในรูปแบบของอุตสาหกรรมมีการฟักไข่ครั้งละจำนวนมากด้วยโรงฟักไข่ที่ทันสมัย ระยะเวลาในการฟักจะแตกต่างกันไปตามชนิดของไข่ที่นำเข้าฟัก เช่น ไข่ไก่ใช้เวลาในการฟัก 21 วัน ไข่เป็ดและไข่ห่าน 28 วัน ไข่เป็ดเทศ 35 วัน ไข่นกกระทา 17 วัน ฯลฯ ซึ่งขั้นตอนการฟักไข่มีการนำไข่เข้าตู้ฟักและมีการส่องไข่ฟักเพื่อตรวจสอบหาไข่มีชีวิต ไข่เชื้อตายหรือสิ่งผิดปกติในฟองไข่จะใช้วิธีส่องไข่ที่ใช้แสงไฟจากหลอดไฟและควรจะทำในที่มืด สำหรับแสงสว่างที่ใช้ต้องมีความเหมาะสมและไม่ร้อนเกินไป เพราะจะเกิดผลเสียต่อตัวอ่อนได้ การส่องไข่เพื่อแยกไข่มีชีวิตและไม่มีชีวิตสามารถทำได้หลังจากนำไข่เข้าฟักไปแล้วเป็นเวลา 15-18 ชั่วโมง แต่ในทางปฏิบัติการส่องไข่จะทำในวันที่ 3 5 7 หรือ 18 ของการฟัก จำนวนครั้งที่ส่องไข่นั้นมีหลายแบบทั้งนี้ขึ้นอยู่กับแรงงาน แต่ในโรงฟักไข่ขนาดใหญ่ที่ทันสมัยในปัจจุบันนี้ จะส่องไข่ในวันที่ย้ายไข่เพียงครั้งเดียวคือวันที่ 18-19 ของการฟัก การส่องไข่ไม่ว่าจะเป็นช่วงใดก็ตามจะมีผลกระทบกระเทือนต่อไข่ฟักไม่มากนักน้อย ซึ่งจะส่งผลถึงการฟักออกเป็นตัวได้ จึงควรทำด้วยความระมัดระวังและใช้เวลาให้น้อยที่สุด (ประภากร ธาราฉาย, 2560) การตรวจสอบที่ไม่แม่นยำหรือผิดพลาดอาจส่งผลกระทบและสร้างความเสียหายภายในตู้ฟัก เพราะไข่ไม่มีชีวิตจะมีปัญหาการเกิดก๊าซไฮโดรเจนซัลไฟด์ ( $H_2S$ ) หรือ แก๊สไข่เน่าส่งผลกระทบต่อไข่ฟองอื่น ๆ ที่อยู่ภายในตู้ฟัก แต่ถ้าเมื่อสามารถจำแนกประเภทของไข่ได้ สามารถเพิ่มพื้นที่ในการเก็บไข่และนำไข่ไม่มีชีวิตออกมาจำหน่ายหรือแปรรูปได้เพื่อเพิ่มผลกำไร ในปัจจุบันการคัดไข่ยังต้องใช้บุคลากรจำนวนมากที่มีความชำนาญในการคัดอยู่และยังใช้ระยะเวลานานในการตรวจสอบ

ดังนั้นสัมมนาฉบับนี้มีวัตถุประสงค์เพื่อศึกษาวิธีการตรวจสอบไข่มีชีวิตแบบอัตโนมัติสำหรับอุตสาหกรรมการฟักไข่

ในงานวิจัยปัจจุบันการพัฒนาการของตัวอ่อนในเปลือกไข่ระยะแรกนั้น วิธีการมองเห็นระบบคอมพิวเตอร์ถูกนำมาใช้อย่างกว้างขวางรวมถึงการเพิ่มประสิทธิภาพของภาพ มีวิธีการนำเสนอในการจำแนกกลุ่มของไข่มีชีวิตและไม่มีชีวิตหลายวิธี (Mahdi and Nacer, 2016) โดยใช้การมองเห็นของเครื่องคุณสมบัติของภาพประกอบไปด้วยพื้นที่ของเส้นเลือดตัวอ่อนในไข่และจุดดำที่สกัดจากภาพ RGB โดยไม่ทำลายเปลือกไข่และเสนออัลกอริธึมการจัดกลุ่มรูปภาพใหม่โดยใช้แบบจำลองที่จำแนกระบบการตรวจสอบโดยเครือข่ายประสาทเทียม Neural Network (Onler et al., 2017) ใช้วิธีการ Ovoscope และ Ultrasound ตรวจจับโดยสัญญาณอัลตราซาวด์ด้วยคลื่นความถี่สูง เก็บรวบรวมภาพแล้วแสดงออกมาบนหน้าจอและบันทึกผล (Geng et al., 2018) ใช้วิธีการ Deep learning จาก CNN ในการจำแนกภาพ ILSVRC (ImageNet การทดสอบการรับรู้ภาพขนาดใหญ่) การประเมินผลการมองเห็นของคอมพิวเตอร์เป็นหนึ่งในชุดข้อมูลการประเมินโมเดล CNN จำนวนมากที่ถูกสร้างขึ้น เช่น Alexnet VGG-Net GoogLeNet ResNet เพื่อเพิ่มประสิทธิภาพเครือข่ายประสาทเทียม

## 1.วิธีการวิจัยและผลการทดลองของบทความ Mahdi and Nacer (2016)

ทำการทดลองไข่จำนวน 240 ฟอง โดยประกอบด้วย ไชมีเชื้อ 190 ฟองและไข่ไม่มีเชื้อ 50 ฟอง แบ่งเป็น 6 ชุด ชุดที่ 1 2 5 6 ไชมีเชื้อ 30 ฟอง ไชมีเชื้อ 10 ฟอง ชุดที่ 3 4 ไชมีเชื้อ 35 ฟอง ไชมีเชื้อ 5 ฟอง ใช้การถ่ายภาพด้วยกล้อง Sony Cyber Shot, DSCWX7 CCD camera ความละเอียดภาพ 720×480 pixels บันทึกไฟล์นามสกุล JPEG ถ่ายภาพ 4 ภาพ ต่อไข่ 1 ฟองทั้งหมด 240 ฟอง ระยะเวลาการฟักที่ทดลอง 5 วัน ได้ภาพ 4,800 ภาพ การประมวลผลภาพและตรวจไข่โดยใช้โปรแกรมที่เขียนด้วยภาษา C++ และเรียกใช้ OpenCV library กระบวนการทำงานบนคอมพิวเตอร์ Intel core i7 CPU และ RAM ขนาด 4 GB โดยระยะเวลาการประมวลผลของแต่ละภาพ ใช้เวลา 0.22 วินาที

ลักษณะอุปกรณ์ที่วางไข่และแหล่งกำเนิดแสงพร้อมกับกล้อง CCD camera ที่ถูกติดตั้งไว้ด้านล่างของ Auto-candling machine ในห้องแล็บแสดงใน Fig. 1 และแหล่งกำเนิดแสงที่ใช้เป็นแสง LED ดังที่แสดงใน Fig. 2 ได้ภาพไข่ที่ถูกถ่ายด้วยกล้อง CCD camera ดังที่แสดงใน Fig. 3



Fig. 1 Auto-candling machine in a laboratory size.

ที่มา : Mahdi and Nacer (2016)



Fig. 2 A close view of the light source.

ที่มา : Mahdi and Nacer (2016)




Fig. 3 A sample digital image taken by the proposed candling-machine.

ที่มา : Mahdi and Nacer (2016)

นำภาพที่ได้แสดงผลในเครื่องคอมพิวเตอร์และเปลี่ยนโหมดสีของภาพจาก RGB เป็นภาพ Grayscale จากนั้นจับภาพเฉพาะรูปที่เป็นไข่แล้วทำให้ภาพชัดเจนนมากขึ้น แล้วใช้อัลกอริทึม Dynamic เพื่อหาเทรชโฮล์ที่เหมาะสมในการแปลงภาพเป็น Binary และขั้นตอนสุดท้ายเป็นขั้นตอนการจำแนกกลุ่มของไข่มีเชื้อและไม่มีเชื้อโดยดูจากอัตราส่วนของฟิสิกเซลล์สีอาหารฟิสิกเซลล์สีขาวดังที่แสดงใน Fig.4




Fig. 4 Outline of the fertility detection process.

ที่มา : Mahdi and Nacer (2016)

ในการทดลองที่ดำเนินการความแม่นยำในการตรวจไข่ที่ได้รับการผสมผลที่ได้ คือ ในวันที่ 1 ได้ความแม่นยำ 47.13% ในวันที่ 2 ได้ความแม่นยำ 81.41% ในวันที่ 3 ได้ความแม่นยำ 93.08% ในวันที่ 4 ได้ความแม่นยำ 97.73% และในวันที่ 5 ได้ความแม่นยำ 98.25%


**Table 1.** Fertility detection accuracy of six sets in five days of incubations.

| Set     | Day             |                 |                 |                 |                 |
|---------|-----------------|-----------------|-----------------|-----------------|-----------------|
|         | 1 <sup>st</sup> | 2 <sup>nd</sup> | 3 <sup>rd</sup> | 4 <sup>th</sup> | 5 <sup>th</sup> |
| Set 1   | 48.15%          | 81.48%          | 92.59%          | 96.30%          | 96.30%          |
| Set 2   | 44.00%          | 80.00%          | 96.00%          | 100.0%          | 100.0%          |
| Set 3   | 50.00%          | 78.13%          | 96.63%          | 96.88%          | 100.0%          |
| Set 4   | 41.18%          | 82.35%          | 94.12%          | 97.06%          | 97.06%          |
| Set 5   | 57.12%          | 85.71%          | 92.86%          | 100.0%          | 100.0%          |
| Set 6   | 42.13%          | 80.77%          | 92.31%          | 96.15%          | 96.15%          |
| Average | 47.13%          | 81.41%          | 93.08%          | 97.73%          | 98.25%          |

ที่มา : Mahdi and Nacer (2016)

การประเมินระบบประสาทเทียมหลังจากการแยกภาพ Binary และการพิจารณาประเภทของไข่ในแต่ละภาพทำการสุ่มเลือก 50% ของภาพในแต่ละชุด ประกอบด้วย 50% ของรูปภาพของไข่มีเชื้อและ 50% ของภาพของไข่ไม่มีเชื้อเพื่อสร้าง Training set ให้ฝึกเครือข่ายประสาทเทียม คุณสมบัติที่สกัดจากรูปภาพ Training set ทำหน้าที่เป็นอินพุตของเครือข่ายประสาทเทียม ส่วนที่เหลืออีก 50% จากภาพจะถูกใช้เป็น Test set สำหรับการประเมินโครงข่ายประสาทเทียม

Neural Network เปรียบเทียบการตรวจจับไข่มีเชื้อโดยค่าความแม่นยำเฉลี่ยความถูกต้องของเครือข่ายประสาทเทียมในระยะ 5 วันของการฟัก เปรียบเทียบกับความแม่นยำเฉลี่ยของระบบที่ไม่ใช้เครือข่ายประสาทเทียมที่ได้จาก Table 1 จากตัวเลขนี้เป็นที่ชัดเจนว่าความแม่นยำของระบบเพิ่มขึ้นเกือบทั้งหมดแต่เพียงเล็กน้อยเท่านั้น



**Fig. 5** Comparison of the average fertility detection accuracy (in percentage) of two systems in five days of incubation process.

ที่มา : Mahdi and Nacer (2016)

## 2.วิธีการวิจัยและผลการทดลองของบทความ Onler et al. (2017)

ทำการทดลองไข่จำนวน 189 ฟอง โดยใช้วิธีการ Ovoscope และ Ultrasound ตรวจจับโดยสัญญาณอัลตราซาวด์ด้วยคลื่นความถี่สูง 3-10 MHz และเปลี่ยนเป็นภาพแสดงออกมาบนหน้าจอและบันทึกลง CD หรือ USB จากการทดลองได้ภาพ 1000 ultrasonographic image ความละเอียดภาพ 32x32 pixels โดยแบ่งเป็น training set 800 ภาพ และ Test set 200 ภาพ ใช้ภาษา Python การเขียนโปรแกรมด้วยการเก็บรวบรวมข้อมูลของ scikit-learn machine ภาพจะถูกส่งมาจาก 6 ตำแหน่งดังที่แสดงใน Fig. 6 และลักษณะที่ตรวจพบไข่มีเชื้อจะต้องมีองค์ประกอบของ Germinal disc ดังที่แสดงใน Fig. 7




Fig. 6 Ultrasound measurement points and the probe position

ที่มา : Onler et al. (2017)




Fig. 7 Structure of fertilized egg

ที่มา : Onler et al. (2017)

ใช้อัลกอริทึม logistic regression ในขั้นตอนการจำแนกกลุ่มของไข่มีเชื้อและไม่มีเชื้อ ได้อธิบายไว้ใน Table 2 ผลการทดลองได้ True positive 350 ภาพ True negative 344 ภาพ Wrong positive 56 ภาพ และ Wrong negative 50 ภาพ ความแม่นยำของแบบจำลองมีค่า 86.75%

**Table 2.** Fertility / Infertility logistic regression classification

|            |            | Predicted Class |           |
|------------|------------|-----------------|-----------|
|            |            | Fertilized      | Infertile |
| Real Class | Fertilized | 350             | 50        |
|            | Infertile  | 56              | 344       |

ที่มา : Onler et al. (2017)

### 3.วิธีการวิจัยและผลการทดลองของบทความ Geng et al. (2018)

ทำการทดลองดูระยะไข่ที่มีการบ่มฟัก 5 วัน โดยใช้วิธีการ Deep learning แบบ CNN ในวิธีมีการประมวลผลชุดข้อมูลที่ใช้ในการฝึกอบรมแบบจำลองสำหรับการจำแนก CNN แบ่งออกเป็นสองสาขา (TB-CNN) ใน Fig. 8 การเริ่มต้นใช้งานใช้พารามิเตอร์โมเดลที่ได้รับการฝึกล่วงหน้าได้มาจากการฝึกอบรมชุดข้อมูลขนาดใหญ่ของ ImageNet กับ AlexNet convolutional (Conv1) ถึง (Pool5) ในสาขาที่สองจะใช้เครือข่ายหลายชั้นวิธีการใช้ในการเริ่มต้นพารามิเตอร์เครือข่ายนี้มีเลเยอร์ convolutional (Conv1\_1 ถึง Conv6\_1) และ (Pool2\_1 ถึง Pool5\_1) แล้วนำ (Pool5) ในสาขาแรกรวมเข้ากับคุณลักษณะของเลเยอร์ Convolutional (Conv6\_1) ในสาขาที่สอง




Fig. 8 TB-CNN Architecture

ที่มา : Geng et al. (2018)

การฝึกอบรมในเครือข่ายที่กล่าวถึงสาขาแรกของเครือข่ายต้องใช้แบบจำลองที่ผ่านการอบรม เราใช้โมเดลที่ได้รับการฝึกฝนมาก่อนซึ่งผ่านการอบรมในชุดข้อมูล ImageNet เพื่อปรับแต่งชุดข้อมูล กระบวนการฝึกอบรมแสดงใน Fig. 9




Fig. 9 Flowing-chart of Training

ที่มา : Geng et al. (2018)

การเตรียมข้อมูลชุดข้อมูลการทดลองมี 2,000 ภาพของการฟักไข่ ซึ่ง 1,200 ภาพจะถูกสุ่มเลือกเพื่อฝึกฝนโมเดล ส่วนที่เหลือ 800 ภาพ จะใช้ในการทดสอบโมเดล

ชุดข้อมูลแบ่งออกเป็นสามประเภท: ไข่มีชีวิต ไข่เชื้อตาย และไข่ไม่มีเชื้อ Fig. 10




Fig. 10 Pretreatment results

ที่มา : Geng et al. (2018)

เปรียบเทียบผลการฝึกอบรมของเครือข่ายกับ TB-CNN และ เครือข่าย Egg-CNN มีสองวิธีนี้เรียกว่า E1-CNN และ E2-CNN วิธีการ E1-CNN ชุดข้อมูลขนาดเล็กได้รับการฝึกอบรมโดยตรงจากเครือข่ายแบบหลายชั้นทั่วไปโดยไม่ต้องเรียนรู้การถ่ายโอนแสดงในรูปที่ a ความแม่นยำขั้นสุดท้ายสูงถึง 95.5% วิธีการ E2-CNN รวมการเรียนรู้การถ่ายโอนเพื่อฝึกอบรมชุดข้อมูล ใช้เครือข่าย AlexNet ในเครือข่ายนี้เฉพาะเลเยอร์การเชื่อมต่อทั้งหมดสุดท้ายเท่านั้นที่ถูกแก้ไขเป็นเลเยอร์คุณลักษณะแบบปรับได้ แสดงในรูปที่ b ชุดเป้าหมายนั้นได้รับการปรับแต่งโดยรุ่นที่ผ่านการฝึกอบรมมาแล้วและผ่านชุดข้อมูล ImageNet ความแม่นยำคือ 97.3%




Fig. 11 The network architecture

ที่มา : Geng et al. (2018)

TB-CNN ความแม่นยำสูงถึง 99.5% ซึ่งดีขึ้นมากเมื่อเทียบกับสองวิธี E1-CNN และ E2-CNN ดังที่แสดงใน Fig. 12 แสดงความแม่นยำของชุดทดสอบในกระบวนการฝึกอบรมแบบจำลอง




Fig. 12 Accuracy and Loss of each network

ที่มา : Geng et al. (2018)

**Table 3.** Comparison of experimental factors

| Article                | Number of eggs | Camera                              | Number of images | Resolution     |
|------------------------|----------------|-------------------------------------|------------------|----------------|
| Mahdi and Nacer (2016) | 240            | Sony Cyber Shot, DSCWX7 CCD camera. | 4,800            | 720×480 pixels |
| Onler et al. (2017)    | 189            | Ultrasound camera                   | 1,000            | 32×32 pixels   |
| Geng et al. (2018)     | -              | CCD camera                          | 2,000            | -              |

ที่มา : ดัดแปลงจาก Mahdi and Nacer (2016); Onler et al. (2017); Geng et al. (2018)

**Table 4.** Comparison of experimental results of analysis

| Article                | Method                                       | Accuracy | Classification              |
|------------------------|----------------------------------------------|----------|-----------------------------|
| Mahdi and Nacer (2016) | A Machine Vision System, Dynamic threshold   | 98.25%   | Fertile, Infertile          |
| Onler et al. (2017)    | Ovoscope and Ultrasound, Logistic regression | 86.75%   | Fertile, Infertile          |
| Geng et al. (2018)     | Deep learning, TB-CNN                        | 99.50%   | Fertile, Dead and Infertile |

ที่มา : ดัดแปลงจาก Mahdi and Nacer (2016); Onler et al. (2017); Geng et al. (2018)

จากการศึกษา ทั้ง 3 งานวิจัยพบว่า Mahdi and Nacer (2016) ใช้วิธีการจำแนกประเภทไข่ด้วยเครื่อง A Machine Vision System และใช้อัลกอริทึม Dynamic threshold มีความแม่นยำอยู่ที่ร้อยละ 98.25 ในการศึกษา Onler et al. (2017) ใช้วิธีการจำแนกประเภทไข่ด้วยวิธีแบบแมนนวล Ovoscope กับ Ultrasound ความแม่นยำอยู่ที่ร้อยละ 86.75 และในการศึกษา Geng et al. (2018) ใช้วิธีการจำแนกประเภทไข่ด้วยโครงข่าย TB-CNN มีความแม่นยำอยู่ที่ร้อยละ 99.50 ดังนั้นในประสิทธิภาพที่ดีที่สุดของวิธีการจากทั้ง 3 งานวิจัยมีความแม่นยำอยู่ในระดับที่สูงแต่มี 1 งานวิจัยที่ให้ผลดีกว่าอีก 2 งานวิจัยคืองานวิจัยของ Geng et al. (2018) ซึ่งใช้โครงข่าย TB-CNN มีความแม่นยำอยู่ที่ร้อยละ 99.50

วิจารณ์ผลการทดลองต้องคำนึงแสงที่ใช้ในการส่องไข่ เพราะแสงที่เหมาะสมทำให้ได้ภาพที่มีความชัดเจนมากขึ้น สายพันธุ์สัตว์และลักษณะสีของไข่ก็อาจมีผลเพราะสีเปลือกไข่มีความแตกต่างกัน ไข่ที่เข้าฟักที่มีเปลือกไข่สีขาวนั้นสามารถส่องเห็นได้ง่ายกว่าไข่ที่มีเปลือกสีน้ำตาล เนื่องจากไข่เปลือกสีน้ำตาลเมื่อส่องดูจะมีลักษณะที่บม่งเห็นรายละเอียดต่าง ๆ ได้ยาก ความหนาของเปลือกไข่ที่อาจส่งผลต่อภาพที่แสดงออกมาในการบันทึกทำให้ผลที่ได้อาจคลาดเคลื่อน ดังนั้นภาพจากกล้องประมวลผลควรเป็นภาพที่ชัดเจนเพื่อให้สามารถวิเคราะห์แยกประเภทของไข่และยังต้องควรคำนึงถึงระยะเวลาในการประมวลผลของภาพแต่ละวิธีด้วยว่าวิธีใดมีการประมวลผลที่รวดเร็วแม่นยำ

การใช้ระบบอัตโนมัติต้องลงทุนอุปกรณ์ต่างๆที่สูง เช่น ไฟส่อง ที่วางไข่เพื่อบรรจุไข่จำนวนหลายฟอง กล้องจับภาพ เครื่องคอมพิวเตอร์ร่วมกับซอฟต์แวร์ในการวิเคราะห์ประมวลผลซึ่งมีราคาค่อนข้างสูงแล้วต้องมีวิธีในการบำรุงรักษาดูแล ดังนั้นจำนวนไข่ที่ตรวจควรคำนึงถึงจุดคุ้มทุนถ้ามีการฟักไข่ในจำนวนน้อย เช่น ครัวเรือน หรืออุตสาหกรรมขนาดเล็กควรใช้การส่องไข่แบบแมนวลมากกว่า แต่ถ้ามีไข่จำนวนมาก เช่น อุตสาหกรรมขนาดกลางหรือขนาดใหญ่ ควรใช้การส่องไข่แบบอัตโนมัติเพื่อลดข้อผิดพลาดที่อาจเกิดขึ้นและลดระยะเวลาให้สั้นลง

## สรุป

จากการศึกษาการตรวจจับไข่ไก่มีเชื้อหรือไม่มีเชื้อ พบว่าการตรวจสอบด้วยวิธีการวิเคราะห์ภาพและโครงสร้างเครือข่ายประสาทเทียมแบบ TB-CNN มีความแม่นยำอยู่ที่ร้อยละ 99.50 เป็นวิธีที่มีศักยภาพ จึงเป็นวิธีจำแนกประเภทไข่มีเชื้อหรือไม่มีเชื้อในอุตสาหกรรมโรงฟัก

อีกทางเลือกหนึ่งในการที่จะนำเอาเทคโนโลยีที่ทันสมัยมาประยุกต์ใช้เพื่อเพิ่มประสิทธิภาพในการตรวจสอบไข่มีเชื้อหรือไม่มีเชื้อ ในการนำระบบนี้ควรคำนึงถึงการใช้ต้นทุนในการติดตั้งระบบ เพราะเหมาะสมสำหรับอุตสาหกรรมขนาดใหญ่ และการนำระบบอัตโนมัติมาใช้ วิธีการวิเคราะห์ภาพปรับปรุงและพัฒนาระบบโครงข่ายให้มีประสิทธิภาพเพื่อเพิ่มความแม่นยำในการตรวจสอบมากขึ้นควรใช้ควบคู่ไปกับบุคลากรที่มีความสามารถและความเข้าใจในระบบนั้น ในอนาคตจะมีแนวโน้มที่สูงขึ้นที่จะนำระบบเทคโนโลยีมาใช้ในเชิงพาณิชย์

## เอกสารอ้างอิง

ประภากร ธาราฉาย. 2560. “บทที่ 5 การฟักไข่”. เอกสารประกอบการเรียนการสอนคณะสัตว

ศาสตร์และเทคโนโลยี มหาวิทยาลัยแม่โจ้. จำนวน 17 หน้า. URL [http://www.as.mju.ac.th/E-Book/t\\_prapakorn.aspx](http://www.as.mju.ac.th/E-Book/t_prapakorn.aspx)

Eray Önlér, İlker H Çelen, Timur Gulhan and Banur Boynukara. 2017. "A study regarding the fertility discrimination of eggs by using ultrasound". **Indian J. Anim.** 51 (2) : 322-326

Mahdi Hashemzadeh, Nacer Farajzadeh. 2016. "A Machine Vision System for Detecting Fertile Eggs in the Incubation Industry". **International Journal of Computational Intelligence Systems.** 850-862

Lei Geng, Tingyu Yan, Zhitao Xiao, Jiangtao Xi, Yuelong Li. 2018. "Hatching eggs classification based on deep learning". **Multimed Tools Appl.** 77:22071–22082