

การประมาณการกินได้ของโคนมด้วยเทคนิคแมชชีนวิชัน
(Feed intake estimation of dairy cows using machine vision techniques)

ศาสตราจารย์ ปกชื้อ

Sattrawut Pokchue

ภาควิชาสัตวศาสตร์ คณะเกษตรศาสตร์ มหาวิทยาลัยอุบลราชธานี

บทคัดย่อ

สัมนานฉบับนี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพและความแม่นยำของการประมาณการกินได้ของโคนมด้วยเทคนิคแมชชีนวิชัน ได้ทำการรวบรวมและศึกษาข้อมูลจากเอกสารวิชาการและสื่ออิเล็กทรอนิกส์จำนวน 3 ฉบับ ตั้งแต่ปี ค.ศ.2016 ถึง ปี ค.ศ.2020 ซึ่งได้ศึกษาการประมาณการกินได้ด้วยวิธีการวิเคราะห์ภาพ พบว่าวิธีการ Quadratic Regression มีค่าความผิดพลาดน้อยกว่า 0.5 กิโลกรัม วิธีการ Convolutional Neural Networks มีค่าความผิดพลาด 0.127 กิโลกรัม และ Photogrammetry software + point cloud processing มีค่าความผิดพลาด 0.483 กิโลกรัม ซึ่งวิธีการ Convolutional Neural Networks ที่มีค่าความผิดพลาด 0.127 กิโลกรัม เป็นวิธีที่ดีที่สุด ดังนั้นผลจากการศึกษาการประมาณการกินได้ของโคนมด้วยเทคนิคแมชชีนวิชันมีความเหมาะสมสำหรับการนำไปใช้ในฟาร์มเชิงพาณิชย์

คำสำคัญ: แมชชีนวิชัน โคนม การประมาณการกินได้

บทนำ

การเลี้ยงโคในปัจจุบันจะมุ่งเน้นไปที่ผลผลิตของโคแต่ละตัว การให้อาหารโคเป็นส่วนสำคัญเนื่องจากการกินได้ของโคจะสัมพันธ์กับสุขภาพและผลผลิตของโคแต่ละตัว โดยโคที่มีสุขภาพดีโดยทั่วไปจะกินอาหารมากกว่าโคที่ไม่แข็งแรง ดังนั้นการตรวจสอบปริมาณการกินได้อย่างเหมาะสมสามารถช่วยในการตัดสินใจในการจัดการฟาร์ม การวัดปริมาณอาหารโคด้วยเครื่องชั่งน้ำหนักสามารถวัดได้แต่เพราะราคาสูงเกินไปสำหรับเกษตรกรส่วนใหญ่และแทบจะใช้เพื่อการวิจัยเท่านั้น นอกจากนี้การตรวจสอบปริมาณอาหารโคสามารถใช้การตรวจสอบด้วยสายตาของมนุษย์ (Bach et al., 2004) แต่มีความยากลำบากในการรวบรวมข้อมูลด้วยตนเอง ในขณะที่บันทึกข้อมูลจะจำกัดขอบเขตของการตรวจสอบประเภทนี้ มีการพัฒนาระบบการประเมินการกินได้หลายระบบในปัจจุบัน เทคโนโลยีอาร์เอฟไอดี (Radio Frequency Identification: RFID) เป็นวิธีการทั่วไปที่ใช้ในการตรวจสอบโคแต่ละตัว ระบบที่ใช้ RFID เช่น GrowSafe Systems, Calan gates และ The Insentec monitoring system ระบบเหล่านี้จะใช้ในสถาบันวิจัยไม่นิยมใช้ในฟาร์มเชิงพาณิชย์เนื่องจากมีราคาที่สูง วิธีการทดลองยังรบกวนพฤติกรรมการกินอาหารตามธรรมชาติของโคเนื่องจากใช้อุปกรณ์กั้นโคกับรางอาหาร และมีปัจจัยธรรมชาติมาเกี่ยวข้องทำให้เกิดข้อผิดพลาดของข้อมูลในการประมาณการกินได้ นอกจากนี้ยังมีระบบที่น่าสนใจคือ ระบบแมชชีนวิชัน

ระบบแมชชีนวิชัน (Machine Vision) เป็นระบบที่ใช้ในการตรวจสอบและวิเคราะห์อัตโนมัติตามการถ่ายภาพ จัดเป็นการเรียนรู้เชิงลึก เป็นการจำลองระบบการมองเห็นของมนุษย์ โดยจะช่วยในดึงข้อมูลจากภาพ เช่น การวิเคราะห์สี การวัด และอื่นๆ (ภานุวัฒน์, 2558) จากนั้นสำหรับการวัดจะเปรียบเทียบกับค่าและความคลาดเคลื่อนที่เหมาะสม มีความสามารถในการประมวลผลภาพและข้อมูลต่างๆ ซึ่งจากรูปแบบความสามารถของระบบในการประเมิน ซึ่งนำมาปรับใช้ในฟาร์มเชิงพาณิชย์เพิ่มมากขึ้น เพื่อหาแนวทางในการลดต้นทุนและแรงงานในการผลิต และสวัสดิภาพความปลอดภัยของสัตว์ (Shelley, 2016)

ดังนั้นสัมมนาฉบับนี้จึงมีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพและความแม่นยำของระบบแมชชีนวิชันเพื่อประมาณการกินได้ของโคนม และการนำไปใช้งานในฟาร์มเชิงพาณิชย์

ระบบแมชชีนวิชัน

ระบบแมชชีนวิชัน (Machine Vision) เป็นเทคโนโลยีและวิธีการที่ใช้ในการตรวจสอบและวิเคราะห์อัตโนมัติ สำหรับการใช้งานเช่นการตรวจสอบอัตโนมัติการควบคุมการเคลื่อนไหวและคำแนะนำหุ่นยนต์ วิชันซิสเต็มใช้กล้องและคอมพิวเตอร์เพื่อทำงานโดยเฉพาะ จากนั้นใช้คอมพิวเตอร์เพื่อวิเคราะห์ภาพและตอบสนองตามข้อมูล ปัจจุบันมีการใช้งาน Machine Vision ในหลายภาคส่วนเช่น ยานยนต์ เกษษกรรม การทหาร อาหารและเครื่องดื่ม อิเล็กทรอนิกส์และอื่น ๆ การใช้งานด้านการมองเห็นของเครื่องจักรในอุตสาหกรรมเช่น การตรวจจับข้อบกพร่องการตรวจสอบผลิตภัณฑ์หรือบรรจุภัณฑ์ การระบุชิ้นส่วนและการติดตามและการวัด เนื่องจากความเร็วความสามารถในการมองเห็นของเครื่องจักรในสายการผลิตสามารถประมวลผลชิ้นส่วนได้หลายร้อยหรือหลายพันชิ้นในแต่ละนาที่ ซึ่งเกินความสามารถของสายตามนุษย์ นอกจากนี้ระบบวิชันซิสเต็มยังสามารถตรวจสอบรายละเอียดชิ้นส่วนที่เล็กเกินกว่าที่ตามนุษย์จะตรวจจับได้ (Wasmund, 2019)

รูป/กราฟแสดงความแม่นยำ




Figure 1. The collected data samples were plotted along with linear (solid line) and quadratic (dashed line) least squares regression models fit to the data comparing the image volume value to the scale weight for the first (a), second (b), and third (c) experimental setups tested. The equations of fit and R² values are shown at right for linear models (in bold) and quadratic models (in gray). These results showed that although a strong linear relationship existed between the scale-measured weight and 3-dimensional volumetric scan data variables (R² = 0.99), a quadratic fit provided a slightly stronger relationship (R² > 0.99).

Source: Shelley et al. (2016)

Figure 1. กราฟแสดงการเปรียบเทียบค่าประมาณน้ำหนักจากภาพกับค่าน้ำหนักที่วัดจริง โดยจะแสดงการเปรียบเทียบในรูปแบบเชิงเส้น (ตัวหนา) และรูปแบบอาร์สแควร์ (สีเทา) ผลลัพธ์แสดงให้เห็นว่าความสัมพันธ์เชิงเส้นของน้ำหนักที่วัดได้จากภาพกับน้ำหนักที่วัดจริงไม่แตกต่างกันและตัวแปรข้อมูลการสแกนเชิงปริมาตร 3 มิติ (R² = 0.99) และเส้นตรงสองเส้นมีความสัมพันธ์ไม่แตกต่างกัน (R² > 0.99)




Figure 2. Weight prediction graph based on all training data after 140 cm fine tuning MAE of 0.127 kg per meal, and a MSE of 0.034 kg² per meal. The total error was 12 kg of two tons distributed in the test data samples.

Source: Bezen et al. (2020)

Figure 2. กราฟการคาดคะเนน้ำหนักจากข้อมูลทดลองทั้งหมดหลังจาก 140 ซม. MAE 0.127 ก.ก. ต่อมี้อ และ MSE 0.034 ก.ก. ข้อผิดพลาดทั้งหมดคือ 12 ก.ก. ของ 2 ตันที่กระจายอยู่ในตัวอย่างข้อมูลการทดสอบ ผลของกราฟแสดงให้เห็นว่าการประมาณน้ำหนักจากรูปภาพไม่แตกต่างจากชั่งน้ำหนักด้วยเครื่องชั่งจริง




Figure 3. The correlation between calculated feed volume and measured feed mass in the laboratory (a) and cowshed conditions (b). Each dot represents a feed heap with a measured mass and calculated volume. The regression line and the error boundary strip are shown by lines. The 3σ error estimation was 0.483 kg for the laboratory experiment and 1.24 kg for the cowshed experiment.

Source: Bloch et al. (2019)

Figure 3. กราฟเปรียบเทียบความสัมพันธ์ระหว่างปริมาณอาหารที่คำนวณได้และมวลอาหารที่วัดได้ในห้องปฏิบัติการ (a) และในคอกวัว (b) แต่ละจุดแสดงถึงกองอาหารที่มีมวลที่วัดได้และปริมาตรที่คำนวณได้ เส้นถดถอยและแถบขอบเขตข้อผิดพลาดแสดงเป็นเส้น การประมาณค่าความคลาดเคลื่อน 3σ ข้อผิดพลาดสำหรับการทดลองในห้องปฏิบัติการคือ 0.483 ก.ก. และข้อผิดพลาดของการทดสอบในคอกวัวประมาณ 1.24 ก.ก. ความผิดพลาดในกราฟนี้ส่วนใหญ่เกิดจากการปิดอัดตามธรรมชาติของอาหาร

Table 1. Summary results

Sourcre	Shelley et al. (2016)	Bezen et al. (2020)	Bloch et al. (2019)
Dairy Cow	-	6	1
Image	13	83	50
Camera	RGB-D camera	RGB-D camera	Nikon camera
Method	Quadratic Regression	Convolutional Neural Networks (CNNs)	Photogrammetry software + point cloud processing
Error	<0.5 kg	0.127 kg	0.483 kg

Source: ดัดแปลงจาก Shelley et al. (2016), Bezen et al. (2020), Bloch et al. (2019)

เปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการประมาณการกินได้ของโคนมด้วยเทคนิคแมชชีนวิชัน สามารถนำมาใช้ในการประมาณการกินได้ของโคนมได้ โดยที่ Bezen et al. (2020) เป็นวิธีการที่มีประสิทธิภาพดีที่สุด มีค่าความผิดพลาด 0.127 กิโลกรัม ที่เป็นเช่นนี้เพราะว่า ใช้วิธีการ Convolutional Neural Networks และกล้อง RGB-D camera เข้ามาในการประมาณการกินได้ ซึ่งใช้จำนวนภาพทั้งหมด 83 ภาพ จึงทำให้ค่าความผิดพลาดน้อยที่สุดเมื่อเทียบกับวิธีการอื่น Shelley et al. (2016) ใช้วิธีการ Quadratic Regression และกล้อง RGB-D camera จำนวนภาพทั้งหมดที่ใช้ 13 ภาพ มีค่าความผิดพลาดน้อยกว่า 0.5 กิโลกรัม เนื่องจากแสงแดดรบกวนเซ็นเซอร์อินฟราเรดของกล้องทำให้มีค่าความห่างกันเมื่อเทียบกับ วิธีการ Bezen et al. (2020) และวิธีการของ Bloch et al. (2019) ใช้ Photogrammetry software + point cloud processing และกล้อง Nikon camera จำนวน 50 ภาพ เนื่องจากการปิดอัดของอาหารตามธรรมชาติทำให้มีค่าความผิดพลาด 0.483 กิโลกรัม

สรุป

จากการศึกษางานวิจัยทั้ง 3 งานบ่งบอกว่าการประมาณการกินได้ด้วยเทคนิคแมชชีนวิชัน มีแนวโน้มนำมาใช้ในการประมาณการกินได้ของโคนมในฟาร์มเชิงพาณิชย์ ซึ่งระบบแมชชีนวิชันสำหรับการวัดปริมาณอาหารโคแต่ละตัวโดยใช้กล้อง RGB-D และอัลกอริธึมการเรียนรู้เชิงลึก เป็นวิธีการที่ดีที่สุด เนื่องจากมีค่าความ

ผิดพลาด 0.127 กิโลกรัม เพราะมีค่าความผิดพลาดการประมาณการกินได้ต่ำที่สุด เมื่อเทียบกับค่าความผิดพลาดการประมาณการกินได้วิธีการอื่น

เอกสารอ้างอิง

ภาณุวัฒน์ เมฆะ. 2558. Machine Vision. <https://erp.mju.ac.th/articleDetail.aspx?qid=445>.

21 ธันวาคม.

Bach A, Iglesias, C., Busto, I., 2004. “A computerized system for monitoring feeding behavior and individual feed intake of dairy cattle”. **J. Dairy Sci.** 87, 4207–4209.

Bezen R, Edan Y and Halachmi I. 2020. “Computer vision system for measuring individual cow feed intake using RGB-D camera and deep learning algorithms”.

Computers and Electronics in Agriculture. 172(2020):10534.

Bloch V, Levit H and Halachmi I. 2019. “ Assessing the potential of photogrammetry to monitor feed intake of dairy cows”. **Journal of Dairy Research.** 86:34–39.

Shelley A.N, Lau D.L, Stone A.E and Bewley J.B. 2016. “Short communication: Measuring feedvolume and weight by machine vision”. **Journal of Dairy Science.** 99: 386–391.

Wasmund R. 2019. **Introduction to Machine Vision Systems.**

<https://conceptsystemsinc.com/introduction-to-machine-vision-systems/>. 21 ธันวาคม.