

**การวิเคราะห์พฤติกรรมการเรียนรู้ในหลักสูตรออนไลน์ระบบเปิด :
การประยุกต์ใช้การเรียนรู้ด้วยเครื่องและการเรียนรู้เชิงลึก**
**Analysis of Learning Behavior in Massive Open Online Courses (MOOCs)
: An Application of Machine Learning and Deep Learning**

อนุสรณ์ เกิดศรี¹

¹ ค.ด. (การวัดและประเมินผลการศึกษา)/มหาวิทยาลัยสุโขทัยธรรมศาสตร์ k.anusorn@hotmail.com

บทคัดย่อ

บทความนี้นำเสนอจุดกำเนิดและการเติบโตของหลักสูตรออนไลน์แบบเปิดที่มีการพัฒนาอย่างรวดเร็ว ซึ่งสะท้อนถึงปริมาณมหาศาลและความหลากหลายของข้อมูล เนื่องจากแพลตฟอร์ม MOOCs สามารถรวบรวมและจัดเก็บข้อมูลจำนวนมากที่เกี่ยวข้องกับกระบวนการเรียนรู้ เรียกว่า ข้อมูลขนาดใหญ่ การใช้ข้อมูลขนาดใหญ่มีความสำคัญอย่างยิ่งในฐานะเครื่องมือในการทำความเข้าใจปรากฏการณ์ที่เป็นปัญหาของการศึกษาทางไกลผ่าน MOOCs อัตราความสำเร็จของ MOOCs ค่อนข้างต่ำ มีหลักฐานเชิงประจักษ์ที่ระบุว่าผู้เรียนมีอัตราการสำเร็จน้อยกว่า 10% บทความนี้มุ่งเน้นที่การนำเทคนิควิธีการสมัยใหม่ ได้แก่ การเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก มาประยุกต์ใช้ในการศึกษาพฤติกรรมการเรียนรู้ของผู้เรียนที่เกิดขึ้นบน MOOCs เพื่อให้ได้สารสนเทศที่นำไปใช้ในการปรับปรุงคุณภาพ MOOCs

คำสำคัญ : การวิเคราะห์การเรียนรู้, ข้อมูลขนาดใหญ่ทางการศึกษา, หลักสูตรออนไลน์แบบเปิดขนาดใหญ่, การเรียนรู้ของเครื่อง, การเรียนรู้เชิงลึก

Abstract

This article presents the origin and growth of the rapidly evolving Massive Open Online Courses that reflect the enormous volume and variety of data. MOOCs platforms are able to collect and store large amounts of data related to the learning process, known as big data. The utilization of big data is of great importance as a tool for understanding the problematic phenomena of distance education through MOOCs. The completion rates of MOOCs appear to be quite low, there is empirical evidence indicating that learners have a completion rate less than 10%. This article focuses on applying modern techniques, including machine learning and deep learning, to study learner learning behavior that occurs on MOOCs to obtain information that is used to improve MOOCs quality.

Keywords: Learning Analytics, Educational Big Data, MOOCs, Machine Learning, Deep Learning

บทนำ

การเรียนรู้ออนไลน์ช่วยให้ผู้เรียนเข้าถึงการศึกษาได้แม้จะมีข้อจำกัดด้านพื้นที่ การเดินทาง และเวลา การพัฒนาที่สำคัญที่สุดอย่างหนึ่งของการเรียนรู้ออนไลน์คือการเกิดขึ้นของหลักสูตรออนไลน์แบบเปิดขนาดใหญ่ (Massive Open Online Courses หรือ MOOCs) การเกิดขึ้นของ MOOCs ทำให้ผู้เรียนทุกคนที่สามารถเชื่อมต่ออินเทอร์เน็ตได้ มีความสะดวก ยืดหยุ่น และประหยัดค่าใช้จ่ายในการเข้าถึงแหล่งเรียนรู้ คำว่า MOOCs ถูกสร้างขึ้นเพื่ออ้างถึงหลักสูตรที่พัฒนาโดย Stephen Downes และ George Siemens ซึ่งมีชื่อว่า Connectivism and Connectivity Knowledge ในปี ค.ศ. 2008 ที่มีความตั้งใจที่จะใช้ประโยชน์จากความเป็นไปได้ในการใช้เทคโนโลยีอินเทอร์เน็ตเพื่อให้เกิดการโต้ตอบระหว่างผู้เรียนที่หลากหลายผ่านเครื่องมือออนไลน์ และสร้างสภาพแวดล้อมการเรียนรู้ที่สมบูรณ์ยิ่งขึ้นกว่าเครื่องมือแบบเดิม เช่น การศึกษาผ่านสื่อสารแบบช่องทางเดียว โดยมีนักศึกษาในวิทยาเขตของมหาวิทยาลัยแมนิโทบา (University of Manitoba) ในประเทศแคนาดา จำนวน 25 คน เข้าร่วมหลักสูตรและอีกประมาณ 2,300 คน จากทั่วโลกเข้าร่วมหลักสูตรผ่านการเชื่อมต่อทางออนไลน์ที่เน้นการโต้ตอบและการมีปฏิสัมพันธ์ที่มีชื่อเรียกว่า cMOOCs หลังจากนั้นในฤดูใบไม้ร่วงปี ค.ศ. 2011 มหาวิทยาลัยสแตนฟอร์ด (Stanford University) ได้เปิดสอนหลักสูตรออนไลน์ฟรี 3 หลักสูตร โดย Peter Norvig และ Sebastien Thrun ได้ทดลองและเปิดหลักสูตร introduction to artificial intelligence มีผู้สนใจจำนวนมากและมีคนกว่า 160,000 คนจากทั่วโลกลงทะเบียนครั้งแรก มีนักศึกษากว่า 20,000 คนจบหลักสูตรหรือคิดเป็นร้อยละ 12.5 ของผู้ลงทะเบียนในครั้งแรก จากที่กล่าวมาจะเห็นความเปลี่ยนแปลงที่เกิดขึ้นเนื่องจาก MOOCs มุ่งเน้นที่การโต้ตอบระหว่างผู้เรียนเรียนน้อยลงและมีการใช้ประโยชน์จากความเป็นไปได้ในการเข้าถึงผู้คนจำนวนมาก การรับรู้และการประชาสัมพันธ์เกี่ยวกับ MOOCs ทำให้มหาวิทยาลัยเกือบทุกแห่งสร้างหลักสูตรอย่างน้อยหนึ่งหลักสูตร การเกิดขึ้นของ MOOCs ถือว่าเป็นการเปลี่ยนแปลงครั้งใหญ่ในระบบการศึกษาทางไกล เพื่อตอบสนองต่อก้าวหน้าทางวิทยาศาสตร์และเทคโนโลยีที่เกิดขึ้นอย่างรวดเร็ว และส่งผลกระทบต่อชีวิตประจำวันและสังคม ประชากรโลกจำเป็นต้องเรียนรู้และปรับตัวให้ทันกับการเปลี่ยนแปลงอยู่เสมอ มีความต้องการความรู้เพิ่มขึ้น เกิดสังคมแห่งความรู้ เรียกว่า “การเรียนรู้ตลอดชีวิต”

ในขณะที่หลักสูตรฟรีทั้ง 3 หลักสูตรของมหาวิทยาลัยสแตนฟอร์ดกำลังดำเนินการอยู่ มหาวิทยาลัยประกาศหลักสูตรเพิ่มเติมโดยแต่ละหลักสูตรมีเว็บไซต์ของตัวเอง ตัวอย่าง เช่น hci-class.org (ปัจจุบันได้เปลี่ยนเส้นทางเข้าถึงเว็บไซต์ไปยัง Coursera) และในปีเดียวกัน สถาบันเทคโนโลยีแมสซาชูเซตส์ (Massachusetts Institute of Technology -- MIT) มีแนวคิดที่จะเสนอหลักสูตรออนไลน์ผ่านแพลตฟอร์ม MITx เพื่อเสนอหลักสูตรออนไลน์ผ่าน MOOCs ต่อมาความร่วมมือกับมหาวิทยาลัยฮาร์วาร์ด (Harvard University) จึงเปลี่ยนชื่อเป็น แพลตฟอร์ม edX ดำเนินการโดยไม่แสวงหากำไรเพื่อพัฒนาและให้บริการ MOOCs ปัจจุบันองค์กรการศึกษาชั้นนำของโลกร่วมมือกับกลุ่มพันธมิตรพัฒนาแพลตฟอร์ม MOOCs ของตนเอง จนกลายเป็นผู้ให้บริการ MOOCs รายใหญ่ของโลก มีผู้ลงทะเบียนในระบบมากกว่า 140 ล้านคน รายละเอียดดังตาราง 1

ตาราง 1 ผู้ให้บริการ MOOCs ชั้นนำของโลก


ผู้ให้บริการ	ผู้เรียน	จำนวนหลักสูตร	Micro credentials	Degrees
Coursera	76 ล้านคน	4,600	680	25
EdX	35 ล้านคน	3,100	385	13
FutureLearn	14 ล้านคน	1,160	86	28
SWAYAM	16 ล้านคน	1,130	0	0

ที่มา: Shah (2020)

ผู้ให้บริการรายใหญ่อีกจำนวน 4 ราย ได้แก่ 1) Coursera เป็นแพลตฟอร์มการศึกษาที่เป็นพันธมิตรกับมหาวิทยาลัยและองค์กรชั้นนำทั่วโลก เพื่อเสนอหลักสูตรออนไลน์สำหรับทุกคนโดยไม่เสียค่าใช้จ่าย 2) EdX เป็นแพลตฟอร์มการเรียนรู้ที่ไม่แสวงหา

ผลกำไรที่สร้างขึ้นโดยมหาวิทยาลัย Harvard และ MIT 3) FutureLearn เป็นแพลตฟอร์มการเรียนรู้ทางสังคมชั้นนำที่ก่อตั้งโดย The Open University และปัจจุบันเป็นเจ้าของร่วมกับ The SEEK Group และ 4) SWAYAM เป็นแพลตฟอร์ม MOOCs ระดับชาติของอินเดีย มีหลักสูตรมากกว่า 2,150 หลักสูตรที่สอนโดยอาจารย์เกือบ 1,300 คน จากมหาวิทยาลัยในอินเดียมากกว่า 135 แห่ง สิ่งที่ทำให้ SWAYAM แตกต่างจากผู้ให้บริการรายอื่นคือนักศึกษาในอินเดียจะได้รับเครดิตการศึกษาออนไลน์ใน SWAYAM

จากการสำรวจหลักสูตรออนไลน์ที่เปิดให้เรียนฟรีโดย Class Central ณ วันที่ 30 พฤศจิกายน ค.ศ. 2020 หลักสูตรออนไลน์ของ MOOCs มีจำนวนมากกว่า 16,300 หลักสูตร ที่เปิดสอนโดยมหาวิทยาลัยมากกว่า 950 แห่งทั่วโลก แสดงในภาพ 1



ภาพ 1 การเติบโตของ MOOCs ตั้งแต่ปี 2012 ถึง 2021

ที่มา: Shah (2020)

จากภาพ 1 ในปี ค.ศ.2020 เพียงปีเดียวมีหลักสูตรเปิดใหม่เพิ่มขึ้นประมาณ 2,800 หลักสูตร (Shah, 2020) ปัจจุบันมีผู้เรียนมากกว่า 180 ล้านคน (ยกเว้นในประเทศจีน) อย่างไรก็ตาม การพัฒนาและดำเนินการ MOOCs นั้นมีค่าใช้จ่ายสูง การพัฒนาและการส่งมอบ MOOCs อาจทำให้สถาบันการศึกษาที่ต้องการให้บริการ MOOCs ต้องเสียค่าใช้จ่ายประมาณ 39,000 ถึง 325,000 เหรียญดอลลาร์สหรัฐต่อหลักสูตร จากตัวเลขค่าใช้จ่ายที่มีราคาสูง หน่วยงานจำเป็นต้องคาดการณ์ประโยชน์ที่คาดว่าจะได้รับว่าคุ้มค่าหรือไม่ เช่น การขยายฐานการเข้าถึงไปยังผู้เรียนที่กว้างขึ้น การสร้างและการรักษาภาพลักษณ์ของสถาบัน และการใช้ MOOCs เป็นการสร้างแหล่งรายได้ที่มีศักยภาพ (Hollands & Tirthali, 2014) นักการศึกษาจึงให้ความสนใจที่จะพิจารณาว่า MOOCs ที่พัฒนาขึ้นประสบความสำเร็จหรือไม่ ทำให้เกิดคำถามว่า “ความสำเร็จของ MOOCs วัดได้อย่างไร” และปัญหาหลักของการใช้ MOOCs คือ ผู้เรียนมีอัตราการสำเร็จการศึกษาในหลักสูตรต่ำมาก ซึ่งคำนวณจากอัตราส่วนของผู้เรียนสำเร็จหลักสูตรกับของจำนวนผู้เรียนทั้งหมดที่ลงทะเบียนเมื่อเริ่มต้นหลักสูตร และผู้เรียนส่วนใหญ่จะมีการเลิกเรียน หรือการออกกลางคัน (Henderikx, Kreijns, & Kalz, 2017) Lee and Choi (2011) ดำเนินการทบทวนวรรณกรรมอย่างเป็นระบบของบทความในวารสารจำนวน 35 บทความ เพื่อตรวจสอบปัจจัยการออกกลางคันระหว่างปี ค.ศ.1999 ถึง 2009 ซึ่งเป็นช่วงที่การศึกษาผ่านช่องทางออนไลน์กำลังเติบโต โดยจัดหมวดหมู่ที่จัดกลุ่มเป็น 3 ปัจจัย ได้แก่ ปัจจัยแรก คือ ปัจจัยด้านนักศึกษา ประกอบด้วย ภูมิหลังทางวิชาการ ประสบการณ์ที่เกี่ยวข้อง ทักษะการบริหารเวลา ความมุ่งมั่นในการทำงาน ความสามารถในการ

สร้างสมดุลระหว่างงานวิชาการและงานวิชาชีพ ความสามารถทางภาษา ปัจจัยที่สอง คือ ปัจจัยด้านหลักสูตร ประกอบด้วย การออกแบบหลักสูตร คุณภาพหลักสูตร การสนับสนุนของสถาบัน และปฏิสัมพันธ์ระหว่างนักเรียนกับผู้สอน ปัจจัยที่สาม คือ ปัจจัยด้านสิ่งแวดล้อม ประกอบด้วย ภาระผูกพันในการทำงาน และสภาพแวดล้อมที่สนับสนุน

ผู้เรียนใน MOOCs ส่วนใหญ่ลงทะเบียนในหลักสูตรโดยไม่ตั้งใจเรียนให้จบหรือไม่ต้องการรับใบรับรอง (Audit student) ผู้เรียนกลุ่มนี้มีอิสระในการเลือกเรียนเฉพาะโมดูลที่สนใจโดยการดาวน์โหลดเอกสารและเรียนรู้ด้วยตนเอง แต่ไม่สามารถขอใบรับรองในการจบหลักสูตรอย่างเป็นทางการได้ ความตั้งใจของผู้เรียนกลุ่มนี้ คือ ต้องการเพิ่มพูนความรู้มากกว่าการได้ใบรับรองในการเรียนจบหลักสูตร (El Said, 2017) ดังนั้นปัญหาการออกกลางคันและปัญหาการคงอยู่ของผู้เรียนใน MOOCs จึงเป็นที่เข้าใจได้เนื่องจากลักษณะการใช้งาน MOOCs มีความเปิดกว้างกลุ่มผู้เรียนมีขนาดใหญ่ เมื่อพิจารณาถึงปรากฏการณ์นี้ ผู้ให้บริการ MOOCs ควรให้ความสนใจกับการเพิ่มอัตราความสำเร็จของผู้เรียนที่ผ่านการตรวจสอบ (Verified student) โดยใช้มาตรการและกลไกต่าง ๆ ในการลดจำนวนผู้ที่ออกกลางคันในกลุ่มผู้เรียนนี้ การเพิ่มประสิทธิภาพของ MOOCs เพื่อให้ผู้เรียนมีอัตราการสำเร็จการศึกษาสูงขึ้น ผู้ให้บริการต้องกำหนดเป้าหมายการเรียนรู้ในหลักสูตรให้เหมาะสมกับพฤติกรรมและความต้องการของผู้เรียน โดยใช้ข้อมูลจำนวนมหาศาลถูกสร้างขึ้นในทุกกิจกรรมการใช้งานของผู้เรียน ข้อมูลในการใช้งานของ MOOCs ในการศึกษา ระดับอุดมศึกษา และการศึกษาระดับวิชาชีพถูกสร้างขึ้นอย่างรวดเร็วในระบบนิเวศการศึกษาซึ่งครอบคลุมระบบและแพลตฟอร์มต่าง ๆ เช่น การจัดการหลักสูตรและระบบการจัดการการเรียนรู้ (LMS) หลักสูตรออนไลน์แบบเปิดขนาดใหญ่ (MOOCs) และเว็บไซต์โซเชียลมีเดีย เช่น Twitter Facebook และ YouTube องค์กรที่มีความสามารถในการปรับขนาดในการประมวลผล และสามารถดำเนินการวิเคราะห์ข้อมูลเหล่านี้ได้จะช่วยให้ได้สารสนเทศเชิงลึกที่จะสร้างประโยชน์ต่อวงวิชาการ ผู้เรียน และระบบนิเวศทางการศึกษา กลุ่มชุมชนทางวิชาการจึงมีความสนใจในการศึกษาในประเด็นเกี่ยวกับการเรียนรู้เชิงลึกจากข้อมูลทางการศึกษาขนาดใหญ่ เพื่อใช้ปรับปรุงประสิทธิภาพการเรียนรู้ของผู้เรียน แนะนำหลักสูตร วิเคราะห์รูปแบบการเรียนรู้ คาดการณ์การออกกลางคัน ปรับปรุงประสิทธิภาพการทำงานของครูสอน และลดภาระงานด้านการบริหาร (Ang, Ge, & Seng, 2020)


บทความนี้เป็นการแสดงให้เห็นตัวอย่างจากการวิจัยที่ใช้การเรียนรู้ของเครื่อง (machine learning -- ML) ในการศึกษาพฤติกรรมการใช้งาน MOOCs ของผู้เรียนจากข้อมูลในการทำกิจกรรมต่าง ๆ บน MOOCs เพื่อให้ได้สารสนเทศเชิงลึกสำหรับการปรับปรุงประสิทธิภาพของ MOOCs โดยมีหัวข้อในการนำเสนอต่อไปนี้ 1) แนวคิดเกี่ยวกับการเรียนรู้ของเครื่อง 2) แนวคิดของการเรียนรู้เชิงลึกที่เกี่ยวข้องกับพฤติกรรมการเรียนรู้ในหลักสูตรออนไลน์แบบเปิด และ 3) การนำการเรียนรู้เชิงลึกมาใช้นำมาผลการเรียนรู้จากพฤติกรรมผู้เรียน ในแต่ละหัวข้อจะมีรายละเอียดดังนี้

แนวคิดเกี่ยวกับการเรียนรู้ของเครื่อง

การเรียนรู้ด้วยเครื่องเกี่ยวข้องกับการพัฒนาและประเมินอัลกอริทึม¹ ที่ทำให้คอมพิวเตอร์เรียนรู้ได้เองโดยไม่ต้องเขียนโปรแกรมสั่งงานให้คอมพิวเตอร์ทำตามทุกครั้งเมื่อนำไปใช้กับชุดข้อมูลที่ไม่เคยพบมาก่อน ในศาสตร์ของการเรียนรู้ของเครื่องมุ่งเน้นไปที่คำถามสำคัญสองคำถาม คือ 1) จะสร้างระบบคอมพิวเตอร์ที่ปรับปรุงตนเองโดยอัตโนมัติผ่านประสบการณ์ได้อย่างไร และ 2) มีกฎพื้นฐานทางทฤษฎีใดบ้างที่ควบคุมระบบการเรียนรู้ที่กระบวน ซึ่งในการเขียนโปรแกรมแบบดั้งเดิม โค้ดของโปรแกรมทั้งหมดจะต้องถูกกำหนดไว้อย่างชัดเจนด้วยกฎหรือขั้นตอนบนพื้นฐานทางตรรกศาสตร์ และคณิตศาสตร์ ในขณะที่ชุดของกฎเกณฑ์ในการเรียนรู้ของเครื่องมีความเป็นพลวัตสามารถปรับเปลี่ยนได้ตามสถานการณ์โดยเรียนรู้ว่า ชุดข้อมูลนำเข้า (Input) และชุดข้อมูลผลผลิต (Output) มีความเกี่ยวข้องสัมพันธ์กันอย่างไร และจะเขียนกฎที่อธิบายความสัมพันธ์ที่มีการเปลี่ยนแปลงเป็นพลวัตในลักษณะของฟังก์ชันที่เป็นโมเดลทางคณิตศาสตร์ โปรแกรมเมอร์ไม่จำเป็นต้องเขียนกฎใหม่ทุกครั้งที่คอมพิวเตอร์ได้รับ

¹ อัลกอริทึม คือ กระบวนการ (หรือสูตร หรือโปรแกรม) ที่คอมพิวเตอร์สามารถทำตามได้ ในบริบทของการเรียนรู้ของเครื่อง อัลกอริทึมจะกำหนดกระบวนการเพื่อวิเคราะห์ชุดข้อมูลและระบุแบบที่เก็ตซ้ำในข้อมูล ตัวอย่างเช่น อัลกอริทึมอาจระบุแบบที่เก็ตซ้ำกับรายได้ประจำปีของบุคคลและหนี้สินในปัจจุบันกับการจัดอันดับความสามารถในการชำระหนี้ในสาขาวิชาคณิตศาสตร์ ความสัมพันธ์ประเภทนี้เรียกว่าฟังก์ชัน

ข้อมูลชุดใหม่ คอมพิวเตอร์จะปรับอัลกอริทึมใหม่ให้เหมาะสมกับชุดข้อมูลนำเข้าเพื่อให้สามารถพยากรณ์ หรือจำแนกผลลัพธ์ได้อย่างมีประสิทธิภาพสูงสุด การเรียนรู้ของเครื่องจำแนกออกเป็น 3 กลุ่มหลัก ตามลักษณะของข้อมูลที่ใช้ในการเรียนรู้ ได้แก่ 1) การเรียนรู้แบบมีผู้สอน 2) การเรียนรู้แบบไม่มีผู้สอน และ 3) การเรียนรู้แบบกึ่งมีผู้สอน ดังแสดงในภาพ 2 ในส่วนของกลุ่มเสริมสามารถจำแนกออกเป็น 3 กลุ่ม ได้แก่ 1) การเรียนแบบเสริมกำลัง 2) การเรียนแบบเลียนแบบ และ 3) การเรียนแบบถ่ายโยงความรู้ บทความนี้จะขยายความเฉพาะการเรียนรู้ของเครื่องในกลุ่มหลักพอสังเขปดังนี้ (El Naqa & Murphy, 2015)



ภาพ 2 การจำแนกหมวดหมู่ของอัลกอริทึมการเรียนรู้ของเครื่องตามลักษณะข้อมูลที่ใช้ในการเรียนรู้

ที่มา: El Naqa and Murphy (2015)

การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นการฝึกให้เครื่องเรียนรู้จากชุดข้อมูลนำเข้าซึ่งเป็นปัญหากับชุดข้อมูลส่งออกที่เป็นผลลัพธ์หรือคำตอบ เช่น การนำข้อมูลนำเข้าที่เป็นไฟล์เสียงกับข้อมูลส่งออกที่เป็นข้อความตามไฟล์เสียงนั้นให้เครื่องเรียนรู้จำนวนมาก ๆ เครื่องจะสามารถบอกได้ว่าเมื่อได้ยินเสียงแบบนี้จะต้องส่งข้อความอะไรออกมา การประยุกต์ใช้การเรียนรู้แบบมีผู้สอน แบ่งได้เป็น 2 แนวทาง คือ ใช้เพื่อจำแนกประเภท (Classification) และใช้เพื่อคาดการณ์หรือพยากรณ์ (Prediction) โดยใช้การวิเคราะห์การถดถอย ข้อแตกต่างของแนวทางทั้ง 2 แบบนี้ คือ ประเภทคำตอบที่เราต้องการใช้กับการเรียนรู้ของเครื่อง ว่ามีจำนวนจำกัด หรือมีจำนวนไม่จำกัด ถ้าคำตอบมีจำนวนจำกัดจะใช้การจำแนกประเภท ถ้าคำตอบมีจำนวนไม่จำกัดจะใช้การพยากรณ์ ซึ่งทั้ง 2 วิธี จำเป็นจะต้องมีตัวอย่างข้อมูลที่ระบุคำตอบว่าการเกิดเหตุการณ์ในแต่ละกรณีคำตอบจะเป็นอะไร หรือมีค่าเท่าใด


การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นการฝึกให้เครื่องเรียนรู้จากชุดข้อมูลนำเข้าอย่างเดียวยังไม่มีภาระระบุเฉลยหรือคำตอบไว้ให้ เช่น งานประเภทการจัดกลุ่มชุดข้อมูล (Clustering) การจัดกลุ่มชุดข้อมูลยังถูกนำไปใช้ในการตรวจสอบค่าสุดโต่ง (Outlier) ที่เรียกว่าการสอบความผิดปกติ (Anomaly detection) เช่น การตรวจสอบความผิดปกติจากการใช้จ่ายผ่านบัตรเครดิต การแจ้งเตือนพฤติกรรมผิดปกติในการสอบออนไลน์ และการวิเคราะห์เพื่อค้นหาความสัมพันธ์ของข้อมูล (Association analysis) เช่น การซื้อสินค้าประเภทเครื่องดื่มในร้านสะดวกซื้อ ผู้ซื้อมักจะซื้อสินค้าอะไร ผู้ซื้อมักจะซื้อสินค้าชนิดใดคู่ไปด้วย หรือ การลงทะเบียนเรียนใน MOOCs ของผู้เรียนในหลักสูตรใด และมักจะลงทะเบียนเรียนในหลักสูตรใดอีก ระบบจะ

ศึกษาความสัมพันธ์ที่เกิดขึ้นแล้วนำเสนอหลักสูตรที่มีแนวโน้มว่าผู้เรียนจะสนใจและเลือกลงทะเบียนเพิ่ม หรือการวิเคราะห์โครงสร้างทางภาษาและการแบ่งแยกคำ (Word segmentation) เช่น การตรวจการคัดลอกงานเอกสารจำนวนมาก โดยอยากทราบว่าชิ้นงานนี้มีการคัดลอกมาจากเอกสารใดหรือไม่ โดยนำชิ้นงานนั้นไปตรวจสอบว่ามีความใกล้เคียงหรือความคล้ายกับเอกสารอื่น หรือแปลกแยกจากเอกสารอื่นมากน้อยระดับใด

การเรียนรู้แบบกึ่งมีผู้สอน (Semi-supervised learning) เป็นการฝึกให้เครื่องเรียนรู้จากชุดข้อมูลส่วนหนึ่งซึ่งระบุเฉลยแล้วและอีกส่วนหนึ่งที่ยังไม่ได้ระบุเฉลย เช่น การแท็กรูปภาพ (image tagging) จำนวนมากเป็นในระดับหลักพัน ถึงระดับหลักล้านภาพ ที่ไม่สามารถใช้แรงงานมนุษย์ในการระบุคำตอบของภาพทั้งหมดได้ในเวลาอันสั้น จึงต้องใช้การเรียนรู้แบบกึ่งมีผู้สอนฝึกให้เครื่องเรียนรู้จากชุดข้อมูลนำเข้าที่มีการระบุคำตอบไว้บางส่วน


แนวคิดของการเรียนรู้เชิงลึกที่เกี่ยวข้องกับพฤติกรรมการเรียนรู้ในหลักสูตรออนไลน์แบบเปิด

การเรียนรู้เชิงลึก (Deep learning) เป็นสาขาย่อยของการเรียนรู้ของเครื่อง (Machine learning) การเรียนรู้ของเครื่องเป็นสาขาย่อยของปัญญาประดิษฐ์ (Artificial intelligence) (Kelleher, 2019) ดังภาพ 3




ภาพ 3 ความสัมพันธ์ระหว่างปัญญาประดิษฐ์ แมชชีนเลิร์นนิง และการเรียนรู้เชิงลึก

ความแตกต่างที่สำคัญที่สุดประการหนึ่งของการเรียนรู้ของเครื่องกับการเรียนรู้เชิงลึก คือ ความสามารถในการปรับขนาดของการเรียนรู้ เมื่อข้อมูลมีขนาดเล็กการเรียนรู้เชิงลึกนั้นทำงานได้ไม่ดี แต่เมื่อปริมาณข้อมูลเพิ่มขึ้น ประสิทธิภาพในการเรียนรู้ทำความเข้าใจและดำเนินการกับข้อมูลของเชิงลึกจะเพิ่มสูงขึ้นแบบก้าวกระโดด ในขณะที่การเรียนรู้ของเครื่องแบบดั้งเดิมไม่ได้ขึ้นอยู่กับปริมาณข้อมูลมากนัก ดังแสดงในภาพ 4 ที่แสดงให้เห็นอย่างชัดเจนว่าอัลกอริทึมการเรียนรู้ของเครื่องอย่างเช่น การเรียนรู้เชิงลึก (Deep learning) จะเจริญเติบโตได้ดีมีความถูกต้องในการทำนายสูงเมื่อได้รับข้อมูลจำนวนมาก อย่างไรก็ตามการเรียนรู้ของเครื่องแบบดั้งเดิม (Traditional ML) และโครงข่ายประสาทเทียมขนาดเล็ก (Shallow NN) ที่มีเซลล์ประสาท/การเชื่อมต่อจำนวนน้อย สามารถให้ผลลัพธ์ที่ดีเมื่อจำนวนข้อมูลที่จำกัด ดังนั้นการเลือกอัลกอริทึมการเรียนรู้ของเครื่องที่เหมาะสมสำหรับปัญหาและปริมาณข้อมูลที่มีอยู่เป็นวิธีที่ง่ายที่สุดในการออกจากกับดักเรื่องปริมาณข้อมูลที่ใช้ในการเรียนรู้ (Vento & Fanfarillo, 2019)




ภาพ 4 การเปรียบเทียบประสิทธิภาพอัลกอริทึมการเรียนรู้ของเครื่องรูปแบบต่าง ๆ ตามปริมาณของข้อมูลในการเรียนรู้
ที่มา: Vento and Fanfarillo (2019)

การเรียนรู้เชิงลึก (Deep learning) เป็นการนำแนวคิดของประสาทวิทยา (Neuroscience) ที่ศึกษาการทำงานของสมองมนุษย์ มาเลียนแบบเพื่อสอนให้คอมพิวเตอร์สามารถเรียนรู้ได้อย่างที่มนุษย์เรียนรู้ การเรียนแบบนั้นเป็นการเลียนแบบการทำงานของสมอง โดยการจำลองโครงสร้างทางสมองของมนุษย์ขึ้นมา เรียกว่า โครงข่ายประสาทเทียม (Artificial neural networks -- ANN) โดยที่เซลล์ประสาท (Neuron) จะถูกเรียกว่า โหนด (Nodes) และมีใยประสาท (Nerve fiber) ที่ทำหน้าที่รับสัญญาณประสาท (Input) เรียกว่า เดนไดรต์ (Dendrite) และส่งสัญญาณประสาท (Output) เรียกว่า แอกซอน (Axon) การประมวลผลในเซลล์ประสาทเทียมจะรับข้อมูลหรือสัญญาณที่ส่งมาจากเซลล์ประสาทที่อยู่ในชั้นก่อนหน้า และมีการประมวลผลเกิดขึ้นเกิดขึ้นภายในกรอบสี่เหลี่ยมโดยเรียกส่วนนี้ว่าโหนด และส่งกระแสสัญญาณที่มีการถ่วงน้ำหนักแล้ว (o_j) ให้เซลล์ประสาทที่อยู่ในชั้นถัดไป ดังภาพ 5 (ข)



ภาพ 5 การเปรียบเทียบส่วนประกอบของเซลล์ประสาทในสมองมนุษย์ (ก) และเซลล์ประสาทเทียม (ข)
ที่มา Chokmani, Khalil, Ouarda, and Bourdages (2021)

จากภาพ 5 เป็นการอธิบายการทำงานของเซลล์ประสาทเทียมจำนวน 1 เซลล์ เท่านั้น แต่ในการเรียนรู้เชิงลึกนั้นเป็นการตั้งชื่อเพื่อสื่อถึง ความลึกของเลเยอร์ในโครงข่ายประสาทเทียม โครงข่ายประสาทเทียมสร้างขึ้นต้องประกอบด้วยชั้นของเซลล์ประสาท (Layer) มากกว่า 3 ชั้น ดังภาพ 6



ภาพ 6 ลักษณะของโครงข่ายประสาทที่มีความลึก


จากภาพ 6 โครงข่ายประสาทประกอบไปด้วย โหนดอินพุต (Input nodes) จำนวน 5 โหนด โหนดชั้นสุดท้ายเรียกว่า โหนดเอาต์พุต (Output nodes) จำนวน 3 โหนด และโหนดที่อยู่ในชั้นซ่อน (Hidden layers) จำนวนหลายชั้น

การเรียนรู้เชิงลึกเป็นเทคโนโลยีใหม่ที่มีแนวโน้มจะถูกนำไปใช้ทางด้านการศึกษา และที่ได้รับความนิยมเพิ่มขึ้นทุกปีในประเด็นของการใช้ปัญญาประดิษฐ์ (Artificial intelligence -- AI) และการเรียนรู้ของเครื่องกับข้อมูลทางการศึกษานับตั้งแต่ปี ค.ศ. 2001 เมื่อพิจารณาถึงความก้าวหน้าทางเทคโนโลยีเกิดขึ้นอย่างรวดเร็วการนำการเรียนรู้เชิงลึกมาใช้ในการศึกษาจึงมีความเป็นไปได้สูง (Huang, Chen, Tzeng, Fang, & Lee, 2018) งานวิจัยที่มีการใช้การเรียนรู้ของเครื่อง หรือการเรียนรู้เชิงลึกในการศึกษาพฤติกรรมกรเรียนรู้ของผู้เรียนบน MOOCs จะทำให้ได้สารสนเทศที่เป็นปัจจัยสำคัญในการปรับปรุงคุณภาพของ MOOCs จากผลการวิจัยก่อนหน้านี้พบว่า MOOCs ที่มีจุดอ่อนในเรื่องอัตราความสำเร็จต่ำและอัตราการออกกลางคันสูง ซึ่งผู้เรียนมีอัตราการสำเร็จไม่เกิน 10% ของผู้ลงทะเบียนทั้งหมด (Wang, Yu, & Miao, 2017) มีรายงานวิจัยจำนวนมากได้เสนอวิธีการทำนายความสำเร็จหรือความล้มเหลวของผู้เรียนในหลักสูตรด้วยแบบจำลองการถดถอยโลจิสติก ซึ่งเป็นอัลกอริทึมการเรียนรู้ของเครื่องประเภทการเรียนรู้แบบมีผู้สอน จากการศึกษาของ Kim et al. (2014) พบว่าความยาวของวิดีโอมีความสัมพันธ์เป็นเชิงลบกับการมีส่วนร่วมอย่างมีนัยสำคัญ นั่นคือ ผู้เรียนมีโอกาสน้อยที่จะดูวิดีโอที่ยาวจนจบ และผู้เรียนมีแนวโน้มที่จะดูวิดีโอจนจบในครั้งแรกแทนที่จะดูมากกว่าหนึ่งครั้ง และ Youngjin Lee (2018) ใช้แบบจำลองการถดถอยโลจิสติกในการตรวจสอบความสัมพันธ์ระหว่างระยะเวลาการทำกิจกรรมในหลักสูตรอย่างต่อเนื่องกับความสำเร็จทางวิชาการของผู้เรียนที่ลงทะเบียนใน MOOCs ในการประเมินความเป็นไปได้ที่นักเรียนจะได้รับใบรับรองหลักสูตรเมื่อสิ้นสุดภาคเรียน พบว่า การเรียนรู้ของผู้เรียนจะหยุดชะงักหากพวกเขาไม่ได้ดูวิดีโอของหลักสูตรเป็นเวลาสองวันติดต่อกัน Lee จึงเสนอเกณฑ์ในการประเมินความถี่และระยะเวลาของการเข้าไปเรียนรู้ของผู้เรียนอย่างต่อเนื่องโดยกำหนดเป็น 3 ระดับ คือ ใช้ระยะเวลา 10 30 และ 60 นาที ผลการเปรียบเทียบการเรียนรู้อย่างต่อเนื่อง พบว่า เกณฑ์ 60 นาที มีความแม่นยำในการทำนายความสำเร็จของผู้เรียนมากที่สุด กล่าวอีกนัยหนึ่ง ผู้เรียนมักจะได้รับใบรับรองหลักสูตรหากเข้าร่วมในกิจกรรมการเรียนรู้มากขึ้นและมีส่วนร่วมในการเรียนรู้เป็นระยะเวลานานขึ้น

การพัฒนาระบบการเรียนรู้เชิงลึกเพื่อทำนายความสามารถของนักเรียนผ่านพฤติกรรมการเรียนรู้ จากตัวอย่างงานวิจัยของ Lee Tzeng Huang and Su (2021) ศึกษาสภาพแวดล้อมการเรียนรู้ของ MOOCs โดยใช้ข้อมูลการดูวิดีโอเพื่อสะท้อนพฤติกรรมการเรียนรู้และประเมินผลการเรียนรู้นอกเหนือจากคะแนนการประเมินที่ได้จากการสอบ และใช้การเรียนรู้เชิงลึกกับข้อมูลการดูวิดีโอเพื่อประเมินว่านักเรียนเข้าใจเนื้อหาหลักสูตรซึ่งช่วยให้ผู้เรียนบรรลุเป้าหมายการเรียนรู้ตามหลักสูตร โดยเฉพาะอย่างยิ่งในหลักสูตรการสอนทางไกลระดับอุดมศึกษาและหลักสูตรฝึกอบรมทางวิชาชีพ การใช้เทคโนโลยีดังกล่าวผู้สอนสามารถติดตามพฤติกรรมการเรียนรู้และประเมินความสามารถของผู้เรียนได้ในหลายมิติ ซึ่งเนื้อหาในส่วนถัดไปจะเป็นการอธิบายเกี่ยวกับรายละเอียดของชุดข้อมูลและโมเดลการเรียนรู้เชิงลึกที่ Lee et al. (2021) ใช้ในการความสามารถของผู้เรียนจากพฤติกรรมการเรียนรู้

การนำการเรียนรู้เชิงลึกมาใช้ทำนายผลการเรียนรู้จากพฤติกรรมผู้เรียน

เนื้อหาในส่วนนี้เป็นการนำเสนอตัวอย่างการใช้การเรียนรู้เชิงลึกในการทำนายผลการเรียนรู้จากพฤติกรรมผู้เรียน ข้อมูลที่เกี่ยวข้องกับการใช้วิดีโอในการเรียนรู้ของผู้เรียน ข้อมูลรายละเอียดพฤติกรรมของผู้เรียนแสดงภาพ 7



ภาพ 7 บันทึกการดูวิดีโอของนักเรียน

ที่มา: Lee et al. (2021)

จากภาพ 7 แสดงถึงความถี่ และระยะเวลาของการดูวิดีโอของผู้เรียนในแต่ละวันในหนึ่งสัปดาห์ จะทำให้เห็นความสม่ำเสมอของการเข้ามาเรียนในรายวิชานั้นของผู้เรียนใน MOOCs ผู้เรียนจะใช้เวลาการเรียนรู้ผ่านวิดีโอประมาณ 15-45 นาที ในวันจันทร์ (Mon) ถึงวันพฤหัสบดี (Thu) จะสังเกตเห็นช่องว่างการเรียนรู้ในวันศุกร์ (Fri) ถึงวันอาทิตย์ (Sun) ซึ่งแสดงถึงจำนวนวันที่ผู้เรียนไม่ได้ใช้ในการเรียนรู้ การที่จะระบุว่าผู้เรียนเข้ามามีส่วนร่วมในการเรียนรู้ ผู้เรียนจะต้องเข้ารับชมวิดีโอมากกว่า 5 นาที จึงจะมีแถบสีปรากฏขึ้นบนภาพ

จากพื้นฐานแนวคิดและความเชื่อที่ว่าผู้เรียนแต่ละคนมีรูปแบบการเรียนรู้และพฤติกรรมการเรียนรู้ที่แตกต่างกัน จึงมีสมมติฐานว่ารูปแบบการเรียนรู้และพฤติกรรมการเรียนรู้ส่งผลต่อความสามารถในการเรียนรู้ของผู้เรียน ดังนั้น เพื่อตรวจสอบสมมติฐานดังกล่าว Lee et al. (2021) จึงนำข้อมูลจาก MOOCs โดยกำหนดโครงสร้างของข้อมูลที่เกี่ยวข้องกับคุณสมบัติพฤติกรรมการดูวิดีโอ เช่น ช่วงเวลาที่เกิดการเรียนรู้หรือเรียกว่าบล็อกการเรียนรู้ ช่องว่าง และความสม่ำเสมอ ดังตารางที่ 2 หลังจากนั้นนำเข้าสู่ข้อมูลเพื่อใช้ในการวิเคราะห์ตามโมเดล Deep Neural Network (DNN) ตามภาพที่ 8 โดยกำหนดฟังก์ชัน

กระตุ้น (activation function²) หรือเรียกอีกอย่างว่าฟังก์ชันการถ่ายโอน (transfer function) เป็นแบบ ReLU³ เพื่อใช้ทำนายความสามารถของผู้เรียน

ตาราง 2 คุณสมบัติของพฤติกรรมการดูวิดีโอ

ชื่อคุณสมบัติ	ความหมาย
videoFinishRate	สัดส่วนของวิดีโอที่เสร็จสิ้น
videoSpendTime	เวลาที่ใช้ดูวิดีโอ/เวลารวมของวิดีโอทั้งหมด
Play	ค่าเฉลี่ยการเล่นในการดูวิดีโอต่อสัปดาห์
gapMean	ค่าเฉลี่ยของวันที่ไม่ได้เรียนต่อสัปดาห์
gapStd	ส่วนเบี่ยงเบนมาตรฐานของ gapMean
regDay	จำนวนวันต่อสัปดาห์ที่ใช้ในการเรียนรู้
weekBlockNumMean	จำนวนบล็อกการเรียนรู้เฉลี่ยต่อสัปดาห์
weekBlockNumStd	ส่วนเบี่ยงเบนมาตรฐานของ BlockNumMean
weekBlockTimeMean	เวลาเฉลี่ยของบล็อกการเรียนรู้ต่อสัปดาห์
dayBlockNumMean	จำนวนบล็อกการเรียนรู้เฉลี่ยต่อวันการเรียนรู้
dayBlockNumStd	ค่าเบี่ยงเบนมาตรฐานของ dayBlockNumMean
dayBlockTimeMean	เวลาเฉลี่ยของบล็อกการเรียนรู้ต่อวันการเรียนรู้
Min15	จำนวนช่วงการเรียนรู้เฉลี่ย >15 นาที/สัปดาห์
Min30	จำนวนช่วงการเรียนรู้เฉลี่ย >30 นาที/สัปดาห์
Min45	จำนวนช่วงการเรียนรู้เฉลี่ย >45 นาที/สัปดาห์
weekNum	จำนวนสัปดาห์ตั้งแต่เริ่มหลักสูตร

* Block (บล็อกการเรียนรู้) คือ บล็อกที่เกิดขึ้นจากการบันทึกข้อมูลการดูวิดีโอของนักเรียนแต่ละคนในภาพ 7


ที่มา: Lee et al. (2021)

ขั้นตอนแรกในการสร้างโมเดลการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก คือ การปรับแต่งคุณลักษณะของข้อมูล (feature engineering) เป็นกระบวนการใช้ความรู้ความเชี่ยวชาญของนักวิทยาศาสตร์ข้อมูลเพื่อสร้าง feature ที่ทำให้อัลกอริทึมการเรียนรู้ของเครื่องประมวลผลข้อมูลได้ เป้าหมายสำคัญของการปรับแต่งคุณลักษณะของข้อมูล คือ การเตรียมชุดข้อมูลนำเข้าที่เหมาะสมกับอัลกอริทึมการเรียนรู้ของเครื่อง เทคนิคในการปรับแต่งคุณลักษณะของข้อมูล มีหลากหลายเทคนิค เช่น การจัดการข้อมูลสูญหาย (Data imputation) การจัดการค่าที่ผิดปกติ (Handling outliers) การแปลงข้อมูลให้อยู่ในรูปแบบมาตรฐานเดียวกัน (Normalization) การแบ่งช่วงข้อมูล การเข้ารหัสข้อมูลให้เป็นตัวเลข 0 1 การแปลงข้อความหรือตัวอักษรให้เป็นตัวเลข และการจัดการกับข้อมูลที่มีการแจกแจงไม่ปกติ ผลของการปรับแต่งคุณลักษณะเฉพาะของข้อมูลจะทำให้โมเดลการเรียนรู้ของเครื่องมีความเสถียรมากขึ้น เมื่อนำข้อมูลชุดใหม่มาทดสอบกับโมเดลการเรียนรู้ของเครื่อง ความแม่นยำหรือความผิดพลาดจะใกล้เคียงกับข้อมูลที่ใช้ฝึกให้โมเดลเรียนรู้

² activation function คือ ฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมดจากทุก Input ภายใน 1 นิวรอน แล้วส่งต่อเป็น Output

³ ReLU ย่อมาจาก Rectified Linear Unit เรียกว่า Ramp function คือถ้า input มีค่าน้อยกว่า 0 output จะถูกเปลี่ยนให้เป็น 0 ถ้า input มีค่ามากกว่า 0 output ก็จะมีค่าเท่ากับ input

ข้อควรระวังในการสร้างโมเดลการทำนายใน MOOCs จะต้องป้องกันไม่ให้มี sparse data หรือข้อมูลที่เป็นช่องว่าง กระจัดกระจายแฝงอยู่ในชุดข้อมูลที่จะนำเข้าสู่โมเดล ถ้ามี sparse data เกิดขึ้นจะส่งผลให้ความถูกต้องในการทำนายลดลง ในการแก้ปัญหานี้ จึงมีการรวบรวมข้อมูลเฉพาะข้อมูลการเรียนรู้ของผู้เรียนที่มีการทำแบบทดสอบ แทนที่จะรวบรวมข้อมูลทั้งหมดจากผู้ลงทะเบียน ในภาพ 8 แสดงสถาปัตยกรรมของแบบจำลองการพยากรณ์ความสามารถของผู้เรียนรวมถึงคุณลักษณะที่ใช้ และจำนวนโหนดในแต่ละเลเยอร์ของ DNN



ภาพ 8 สถาปัตยกรรมของแบบจำลองการทำนายคะแนนตามพฤติกรรมการดูวิดีโอ

ที่มา: Lee et al. (2021)

ตัวประเมินประสิทธิภาพของโมเดลจะพิจารณาจาก ค่าเฉลี่ยความคลาดเคลื่อนแบบสัมบูรณ์ (Mean absolute error -- MAE) แสดงความแตกต่างระหว่างคะแนนที่ทำนายได้กับคะแนนจริง โดยค่า MAE ที่ต่ำกว่าบ่งชี้ถึงประสิทธิภาพการทำนายที่ดีขึ้น ค่า MEA คำนวณจากสูตรต่อไปนี้

$$MEA = \frac{1}{N} \sum_{i=1}^N |f_i - y_i|$$

โดยที่ f_i แทน ค่าคะแนนที่ถูกทำนายได้ของคนที่ i

y_i แทน ค่าคะแนนสอบจริงของคนที่ i

N แทน ค่าจำนวนของผู้เรียนในชุดข้อมูล

การทดสอบเพื่อประเมินประสิทธิภาพของโมเดลจะใช้เทคนิคที่เรียกว่า k-fold cross validation เป็นการแบ่งข้อมูลอย่างสุ่มเป็น k ส่วนเท่า ๆ กันเพื่อสร้างและทดสอบโมเดล (Train และ Validate) จากนั้นจึงคำนวณค่าเฉลี่ยตัวประเมิน

ประสิทธิภาพของโมเดล ซึ่งใช้ค่า MEA ก่อนที่จะนำโมเดลไปใช้ทำนายด้วยชุดข้อมูลสำหรับการทดสอบ ซึ่งการทำ k-fold cross validation จะได้ผลลัพธ์ที่น่าเชื่อถือมากขึ้นเพราะเป็นการสร้างและทดสอบโมเดลมากกว่าหนึ่งรอบโดยมีการเปลี่ยนชุดข้อมูลที่นำมาใช้ฝึกและทดสอบโมเดลทุกครั้ง เป็นการช่วยลดปัญหาที่เกิดจากโมเดลสามารถพยากรณ์ผลลัพธ์ได้แม่นยำมากเมื่อใช้ข้อมูลจากชุดฝึกแต่เมื่อนำไปตรวจสอบโมเดลกับข้อมูลที่เป็นชุดทดสอบสามารถพยากรณ์ผลลัพธ์ได้แม่นยำต่ำ หรือเรียกว่า overfitting เพื่อให้ผู้อ่านเข้าใจชัดเจน จึงนำเสนอตัวอย่างของแบบแผนการทำ 5-fold cross validation มีรายละเอียดดังตาราง 3

ตาราง 3 แบบแผนการทำ 5-fold cross validation

รอบของการทดสอบ	Train Folds	Validation Fold	MEA
1	1, 2, 3, 4	5	xx.xx
2	1, 2, 3, 5	4	xx.xx
3	1, 2, 4, 5	3	xx.xx
4	1, 3, 4, 5	2	xx.xx
5	2, 3, 4, 5	1	xx.xx
ค่าเฉลี่ยของ MEA			xx.xx

จากการวิจัยของ Lee et al. (2021) ที่ได้ทำการทดสอบเพื่อประเมินประสิทธิภาพของโมเดลโดยใช้ 10-fold cross validation ซึ่งเปรียบเทียบโมเดลการเรียนรู้เชิงลึกแบบ 6 7 และ 8 เลเยอร์ ผลการทดสอบ พบว่า เมื่อกำหนดโมเดลการเรียนรู้เชิงลึกตามภาพที่ 4 เป็น 8 เลเยอร์ จะมีค่าเฉลี่ยความคลาดเคลื่อนแบบสัมบูรณ์ (Mean Absolute Error -- MAE) ต่ำที่สุดคือ 6.8 จากนั้นจึงนำโมเดลที่มีประสิทธิภาพดีที่สุดไปใช้ประเมินผลการเรียนจากพฤติกรรมการเรียนรู้กับข้อมูลผู้เรียนในหลักสูตรอินเทอร์เน็ตของสรรพสิ่งเบื้องต้น ที่มีรายละเอียดดังตาราง 4

ตาราง 4 รายละเอียดของหลักสูตร

ตัวแปร	บทนำสู่อินเทอร์เน็ตของสรรพสิ่ง	แคลคูลัส
ช่วงเวลาที่เปิด	March 2–June 29, 2020	May 1–August 31, 2020
จำนวนนักเรียน	255	1,062
จำนวนวิดีโอ	87	144
จำนวนสัปดาห์ที่เปิดให้เรียน	5	12
ค่าเฉลี่ยความยาวของวิดีโอ (วินาที)	525	792
จำนวนแบบฝึกหัด	71	142
จำนวนแบบทดสอบ	1	3
จำนวนข้อสอบในแต่ละแบบทดสอบ	50	20
ช่วงเวลาที่ให้ทำแบบทดสอบ	5	4
คุณสมบัติในการสมัครเรียนในหลักสูตร	ไม่มี	สำหรับผู้ที่ศึกษาในระดับมัธยมปลายเท่านั้น
ค่าธรรมเนียม	ฟรี	จ่ายค่าธรรมเนียม

ที่มา: Lee et al. (2021)

จากตาราง 4 หลักสูตรอินเทอร์เน็ตของสรรพสิ่งเบื้องต้น (Introduce to the Internet of Things) จะทำการสอปลายภาคเพื่อประเมินผลการการเรียนรู้ของนักเรียนครั้งเดียว ในขณะที่หลักสูตรแคลคูลัส 1 จะทำการทดสอบเพื่อประเมินผลการเรียนรู้ของผู้เรียน 3 ครั้ง แต่แต่ละครั้งห่างกัน 4 สัปดาห์ จึงได้สร้างโมเดลการทำนายความสามารถของผู้เรียนทุกสัปดาห์เพื่อให้เห็นแนวโน้มประสิทธิภาพของโมเดล ในบทความนี้นำตัวอย่างการใช้โมเดลการเรียนรู้เชิงลึกสำหรับทำนายความสามารถของผู้เรียนที่เรียนในหลักสูตรอินเทอร์เน็ตของสรรพสิ่งเบื้องต้นเพียงตัวอย่างเดียว ตัวอย่างอื่นสามารถศึกษาเพิ่มเติมได้จากงานวิจัยของ Lee et al. (2021)

ผลการประเมินประสิทธิภาพการทำนายความสามารถของผู้เรียนที่เรียนในหลักสูตรอินเทอร์เน็ตของสรรพสิ่งเบื้องต้นด้วยโมเดลการเรียนรู้เชิงลึก แสดงในตาราง 5

ตาราง 5 ผลการประเมินประสิทธิภาพการทำนายความสามารถของผู้เรียนที่เรียนในหลักสูตรอินเทอร์เน็ตของสรรพสิ่งเบื้องต้นด้วยโมเดลการเรียนรู้เชิงลึก 8 เลเยอร์

	MAE
1	18.2
2	13.6
3	10.1
4	7.9
5	6.9

ที่มา: Lee et al. (2021)

จากตาราง 5 ค่า MAE เมื่อเรียนจบสัปดาห์ที่ 1 มีค่าเท่ากับ 18.2 แสดงให้เห็นว่าคะแนนที่ทำนายความสามารถของผู้เรียนในช่วงเริ่มต้นเรียนกับคะแนนที่ได้จากการทำแบบทดสอบจริงมีความแตกต่างกันอย่างมาก อย่างไรก็ตาม ประสิทธิภาพของโมเดลจะดีขึ้นเมื่อเรียนจบสัปดาห์ที่ 5 (จะมีข้อมูลพฤติกรรมการเรียนรู้ของผู้เรียนทั้งหมดตลอดระยะเวลาของหลักสูตร) ทำให้ค่า MAE ลดลงเหลือเพียง 6.9 ซึ่งบ่งชี้ว่าแบบจำลองของการเรียนรู้เชิงลึกที่สร้างขึ้นมีความแม่นยำที่ยอมรับได้ นั่นคือ คะแนนโดยเฉลี่ยที่ได้จากการทำนายด้วยพฤติกรรมการเรียนรู้ของผู้เรียน มีค่าแตกต่างจากคะแนนทำได้จากการทำแบบทดสอบจริง โดยเฉลี่ย ± 6.9 คะแนน

สรุป

ในปัจจุบันการเรียนผ่าน MOOCs ได้รับความนิยมอย่างสูง มีผู้ใช้งานจากทั่วโลกมากกว่า 180 ล้านคน มีหลักสูตรให้ศึกษามากกว่า 16,000 หลักสูตร แต่จำนวนผู้เรียนที่เรียนสำเร็จการศึกษาตามหลักสูตรมีจำนวนน้อยกว่าร้อยละ 10 ของผู้ลงทะเบียน นักวิชาการจำนวนมากพยายามค้นคว้าเพื่ออธิบายพฤติกรรมของผู้เรียนที่เกี่ยวข้องกับสาเหตุของการออกกลางคัน เพื่อนำสารสนเทศที่ได้ไปปรับปรุงพัฒนาหลักสูตรออนไลน์ของ MOOCs เพื่อสร้างความสนใจให้ผู้เรียนเข้ามามีส่วนร่วมกับกิจกรรมที่ผู้สอนออกแบบไว้ในหลักสูตรโดยไม่ทิ้งระยะห่างจากการเข้ามาในหลักสูตรนานเกินไปจนขาดความสนใจและละทิ้งการเรียน ความก้าวหน้าทางเทคโนโลยีที่เพิ่มขึ้นอย่างรวดเร็วประกอบกับปริมาณข้อมูลที่เพิ่มขึ้นอย่างมหาศาลจากผู้ใช้งานจำนวนมาก จึงมีความเป็นไปได้ที่จะนำการเรียนรู้เชิงลึกมาใช้กับข้อมูลขนาดใหญ่ทางการศึกษาเพื่อปรับปรุงความสามารถของ MOOCs โดยพิจารณาจากพฤติกรรมการเรียนรู้ของผู้เรียน ที่เกิดจากการปฏิสัมพันธ์ของผู้เรียนกับระบบ MOOCs มีรูปแบบที่หลากหลายนอกเหนือจากการศึกษาผ่านพฤติกรรมการดูวิดีโอ เช่น การคลิกเพื่อเข้าชมบทความหรือสื่อการศึกษาอื่นที่ผู้สอนจัดเตรียมให้ ระยะเวลาที่ผู้เรียนใช้กับส่วนต่าง ๆ ของ MOOCs การมีส่วนร่วมกับหลักสูตรที่เปิดสอนผ่านกระดานสนทนา การทำแบบฝึกหัด

หรือกิจกรรมประจำโมดูล ข้อมูลเหล่านี้เปรียบเสมือนรอยเท้าของผู้เรียนที่เดินไปศึกษาตามจุดต่าง ๆ บน MOOCs กิจกรรมและจำนวนของผู้เรียนที่เพิ่มขึ้นจำนวนมาก สะท้อนถึงข้อมูลจำนวนมากที่เพิ่มขึ้นทุกวันและสะสมอยู่ในระบบเปรียบเสมือนชั้นของพื้นดินที่อัดแน่นไปด้วยทรัพยากรหรือสินแร่จำนวนมาก การใช้เรียนรู้เชิงลึกกับข้อมูลจำนวนมากเหล่านี้ เป็นการสกัดหาสารสนเทศสำคัญที่อธิบายปรากฏการณ์ของปัญหาที่เกิดขึ้นในการจัดการเรียนการสอนผ่านหลักสูตรออนไลน์ระบบเปิด ทำให้ได้ข้อมูลย้อนกลับที่สามารถนำไปใช้ปรับปรุงคุณภาพของ MOOCs ให้ดีขึ้น สร้างความสนใจให้ผู้เรียนเข้ามามีส่วนร่วมกับกิจกรรมที่จัดไว้ในแต่ละโมดูลมากขึ้น การศึกษาพฤติกรรมของผู้เรียนยังสามารถสร้างระบบการแจ้งเตือนที่สามารถแนะนำแนวทางการเรียนรู้ที่สามารถปรับให้ผู้เรียนบรรลุตามเป้าหมายของหลักสูตรได้ ระบุกลุ่มผู้เรียนที่คาดว่าจะมีผลการเรียนต่ำและให้การสนับสนุนเพิ่มเติมเป็นการกระตุ้นให้ผู้เรียนมีอัตราการสำเร็จตามหลักสูตรเพิ่มมากขึ้น เป็นการลดข้อจำกัดด้านเวลา จากการแจ้งเตือนที่ล่าช้า โดยปกติผู้เรียนจะได้รับการประเมินในช่วงท้ายของการเรียนจบในแต่ละโมดูล หรือประเมินเพียงครั้งเดียวตลอดหลักสูตร เป็นการลดการสูญหายของผู้เรียนระหว่างเรียน และเพิ่มอัตราการสำเร็จของในแต่ละหลักสูตร และจากตัวอย่างงานวิจัยที่ยกขึ้นมาประกอบจะทำให้ผู้อ่านมองเห็นภาพการประยุกต์ใช้การเรียนรู้เชิงลึกกับข้อมูลทางการศึกษาขนาดใหญ่อย่างละเอียดทีละขั้นตอน ตั้งแต่การระบุโครงสร้างของข้อมูลที่ต้องการเก็บ เทคนิคการสุ่มตัวอย่างซ้ำ (resampling) เพื่อใช้ในการประเมินโมเดลการเรียนรู้เชิงลึก ดัชนีที่ใช้พิจารณาความถูกต้องในการทำนาย ตลอดจนการนำโมเดลการเรียนรู้เชิงลึกไปใช้จริง และการแปลผลการใช้โมเดลการเรียนรู้เชิงลึก นอกจากนี้ผู้อ่านสามารถสืบค้นแบบย้อนรอยตามรายการอ้างอิง เพื่อศึกษารายละเอียดเพิ่มเติมในประเด็นที่สนใจ

เอกสารอ้างอิง

- Ang, K. L., Ge, F. L., & Seng, K. P. (2020). Big educational data & analytics: survey, architecture and challenges. *IEEE Access*, 8, 116392-116414. doi:10.1109/ACCESS.2020.2994561
- Chokmani, K., Khalil, B., Ouarda, T., & Bourdages, R. (2021). Estimation of river ice thickness using artificial neural networks. *Proceedings of the 14th Workshop on the Hydraulics of Ice Covered Rivers*. CGU HS Committee on River Ice Processes and the Environment (CRIPE), Québec, Canada. 12 pp.
- Del Vento, D., & Fanfarillo, A. (2019). Traps, pitfalls and misconceptions of machine learning applied to scientific disciplines. *Pearc '19 Proceedings of the Practice And Experience In Advanced Research Computing On Rise Of The Machines*, 75. doi:10.1145/3332186.3332209
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning? In I. El Naqa, R. Li, & M. J. Murphy (Eds.), *Machine learning in radiation oncology: theory and applications* (pp. 3-11). Cham: Springer International Publishing.
- El Said, G. R. (2017). Understanding how learners use massive open online courses and why they drop out: thematic analysis of an interview study in a developing country. *Journal of Educational Computing Research*, 55(5), 724-752. doi:10.1177/0735633116681302
- Henderikx, M. A., Kreijns, K., & Kalz, M. (2017). Refining success and dropout in massive open online courses based on the intention– behavior gap. *Distance Education*, 38(3), 353- 368. doi: 10.1080/ 0158 7919.2017.1369006
- Hollands, F. M., & Tirthali, D. (2014). *MOOCs: Expectations and Reality. Full Report*. Retrieved from <http://files.eric.ed.gov/fulltext/ED547237.pdf>

- Huang, N., Chen, C., Tzeng, J., Fang, T. T., & Lee, C. (2018). *Concept Assessment System Integrated with a Knowledge Map Using Deep Learning*. Paper presented at the 2018 Learning With MOOCSS (LWMOOCSS).
- Kavlakoglu, E. (2020). *AI vs. machine learning vs. deep learning vs. neural networks: what's the difference?* Retrieved from <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>
- Kelleher, J. D. (2019). *Deep learning*: MIT Press.
- Kim, J., Guo, P. J., Seaton, D. T., Mitros, P., Gajos, K. Z., & Miller, R. C. (2014). *Understanding in-video dropouts and interaction peaks in online lecture videos*. Paper presented at the Proceedings of the first ACM conference on Learning @ scale conference, Atlanta, Georgia, USA. <https://doi.org/10.1145/2556325.2566237>
- Lee, C.-A., Tzeng, J.-W., Huang, N.-F., & Su, Y.-S. (2021). Prediction of student performance in massive open online courses using deep learning system based on learning behaviors. *Educational Technology & Society*, 24(3), 130-146. Retrieved from <https://www.jstor.org/stable/27032861>
- Lee, Y. (2018). Effect of uninterrupted time-on-task on students' success in Massive Open Online Courses (MOOCs). *Computers in Human Behavior*, 86, 174-180. doi:<https://doi.org/10.1016/j.chb.2018.04.043>
- Lee, Y., & Choi, J. (2011). A review of online course dropout research: implications for practice and future research. *Educational Technology Research and Development*, 59(5), 593-618. doi:10.1007/s11423-010-9177-y
- Shah, D. (2020). Analysis By The Numbers: MOOCs in 2020. Retrieved from <https://www.class-central.com/report/MOOCs-stats-2020/>
- Wang, W., Yu, H., & Miao, C. (2017). *Deep model for dropout prediction in MOOCs*. Paper presented at the Proceedings of the 2nd International Conference on Crowd Science and Engineering, Beijing, China. <https://doi.org/10.1145/3126973.3126990>

