



การเรียนรู้เชิงลึก (Deep Learning)

โดยใช้ **Python** เพื่อวิเคราะห์ธุรกิจ



- อธิบายหลักการเรียนรู้เชิงลึกอย่างละเอียดเป็นลำดับขั้นตอน
- มีตัวอย่างประกอบเน้นการประยุกต์ใช้งานได้จริง
- ทหน่วยงานและองค์กรต่าง ๆ สามารถนำความรู้ไปแก้ปัญหาด้านธุรกิจ
- ขยายผลต่อยอดการทำงานต่อไปได้ เหมาะกับผู้อ่านที่สนใจทุกระดับ

รศ.ดร. วุฒิชัย ร่มสายทฤษฎ์

AI การเรียนรู้เชิงลึก (Deep Learning) โดยใช้ Python เพื่อวิเคราะห์ธุรกิจ

โดย รศ.ดร. วุฒิชัย ร่มสายหยุด

สงวนลิขสิทธิ์ตามกฎหมาย โดย รศ.ดร. วุฒิชัย ร่มสายหยุด © พ.ศ.2568

ห้ามคัดลอก ลอกเลียน ดัดแปลง ทำซ้ำ จัดพิมพ์ หรือกระทำการอื่นใด โดยวิธีการใดๆ ในรูปแบบใดๆ ไม่ว่าส่วนหนึ่งส่วนใดของหนังสือเล่มนี้ เพื่อเผยแพร่ในสื่อทุกประเภท หรือเพื่อวัตถุประสงค์ใดๆ นอกจากจะได้รับอนุญาต

ข้อมูลทางบรรณานุกรมของหอสมุดแห่งชาติ

วุฒิชัย ร่มสายหยุด.

AI การเรียนรู้เชิงลึก (Deep Learning) โดยใช้ Python เพื่อวิเคราะห์ธุรกิจ. -- กรุงเทพฯ : ซีเอ็ดดูเคชั่น, 2568.

232 หน้า.

1. ปัญญาประดิษฐ์ -- การประมวลผลข้อมูล. 2. ปัญญาประดิษฐ์.

I. ชื่อเรื่อง.

006.3

Barcode (e-book) : 9786160854967

จัดพิมพ์และจัดจำหน่ายโดย



บริษัท ซีเอ็ดดูเคชั่น จำกัด (มหาชน)
SE-EDUCATION PUBLIC COMPANY LIMITED

เลขที่ 1858/87-90 ถนนเทพรัตน แขวงบางนาใต้ เขตบางนา กรุงเทพฯ 10260

โทรศัพท์ 0-2826-8000

หากมีคำแนะนำหรือติชม สามารถติดต่อได้ที่ comment@se-ed.com



คำนำ

หนังสือ AI การเรียนรู้เชิงลึก (Deep Learning) โดยใช้ Python เพื่อวิเคราะห์ธุรกิจเล่มนี้มีจุดประสงค์เพื่อถ่ายทอดความรู้ด้านการเรียนรู้เชิงลึกทั้งในเชิงทฤษฎีและการประยุกต์ใช้งานจริงในบริบททางธุรกิจ โดยมุ่งเน้นให้ผู้อ่านเข้าใจหลักการพื้นฐานของการเรียนรู้เชิงลึก และสามารถนำไปประยุกต์ใช้งาน

เนื้อหาประกอบด้วย 2 ส่วนหลักได้แก่ (1) ภาคทฤษฎี ได้แก่บทที่ 1 หลักการเรียนรู้เชิงลึก และบทที่ 2 กระบวนการและอัลกอริทึมการเรียนรู้เชิงลึก และ (2) ภาคประยุกต์ นำเสนอโจทย์ปัญหาและตัวอย่างการพัฒนาแบบจำลองด้วยภาษาไพธอน (Python) กับการทำงานด้านต่างๆ ด้วยอัลกอริทึมการเรียนรู้เชิงลึก โดยในบทที่ 3 โครงข่ายประสาทเทียม (Artificial Neural Network) และการประยุกต์ใช้ในการจำแนกรูปภาพ บทที่ 4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) และการประยุกต์ใช้ในการจำแนกการแสดงออกทางอารมณ์บนใบหน้า บทที่ 5 หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) และการประยุกต์ใช้ในการพยากรณ์ราคาทองคำ บทที่ 6 โครงข่ายปรปักษ์เชิงสร้างสรรค์ (Generative Adversarial Networks) และการประยุกต์ใช้ในการตรวจจับการฉ้อโกงทางการเงินในระบบธนาคาร บทที่ 7 การเรียนรู้การถ่ายโอน (Transfer Learning) บทที่ 8 การปรับใช้แบบจำลองการเรียนรู้เชิงลึกในเว็บแอปพลิเคชันด้วย Flask Framework และ บทที่ 9 การแสดงผลข้อมูลของแบบจำลองการเรียนรู้เชิงลึกด้วย TensorBoard ทำให้หนังสือเล่มนี้เป็นหนังสือแบบครบวงจร (end-to-end)

ผู้เขียนหวังเป็นอย่างยิ่งว่าหนังสือเล่มนี้จะประโยชน์แก่ผู้อ่านในการทำความเข้าใจหลักการการเรียนรู้เชิงลึกและการประยุกต์ใช้งานจริง หรือสามารถต่อยอดเพื่อพัฒนาแบบจำลองการเรียนรู้เชิงลึกสำหรับงานเฉพาะด้านของผู้อ่านต่อไปได้ และสามารถดาวน์โหลดคำสั่งและแหล่งข้อมูลที่เกี่ยวข้องได้ที่ GitHub: <https://github.com/walisa-stou/SE-ED-DL-book> หรือ YouTube: <https://www.youtube.com/@aj-walisa>



สารบัญ

บทที่ 1 หลักการเรียนรู้เชิงลึก (Principles of Deep Learning)	9
1.1 ความหมายและประเภทของการเรียนรู้เชิงลึก	9
1.2 ความสัมพันธ์ระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก	12
1.3 กระบวนการทำงานของการเรียนรู้เชิงลึก	13
1.4 ตัวอย่างอัลกอริทึมการเรียนรู้เชิงลึก	14
1.5 เครื่องมือสำหรับการเรียนรู้เชิงลึก	16
1.6 ชุดข้อมูลมาตรฐานของการเรียนรู้เชิงลึก	17
1.7 ตัวอย่างการประยุกต์การเรียนรู้เชิงลึก	19
1.8 การเตรียมสภาพแวดล้อมและการจัดการข้อมูลขนาดใหญ่	20
สรุปเนื้อหาบทที่ 1	26
บทที่ 2 กระบวนการและอัลกอริทึมการเรียนรู้เชิงลึก (Process and Algorithms of Deep Learning)	27
2.1 กระบวนการเรียนรู้เชิงลึก	27
2.2 การทำงานของอัลกอริทึมการเรียนรู้เชิงลึก	46
สรุปเนื้อหาบทที่ 2	57
บทที่ 3 โครงข่ายประสาทเทียม (Artificial Neural Network) และการประยุกต์ใช้ในการจำแนกรูปภาพ	59
3.1 โครงข่ายประสาทเทียม	59
3.2 การประยุกต์โครงข่ายประสาทเทียมในการจำแนกรูปภาพ	73
สรุปเนื้อหาบทที่ 3	79

บทที่ 4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) และการประยุกต์ใช้ในการจำแนกการแสดงผลออกทางอารมณ์บนใบหน้า.. 81

4.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน	81
4.2 การประยุกต์โครงข่ายประสาทเทียมแบบคอนโวลูชันในการจำแนก การแสดงผลออกทางอารมณ์บนใบหน้า	101
สรุปเนื้อหาบทที่ 4.....	114

บทที่ 5 หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) และการประยุกต์ใช้ในการทำนายราคาทองคำ 115

5.1 หน่วยความจำระยะสั้นแบบยาว	115
5.2 การประยุกต์หน่วยความจำระยะสั้นแบบยาวในการทำนายราคาทองคำ	131
สรุปเนื้อหาบทที่ 5.....	141

บทที่ 6 โครงข่ายปรปักษ์เชิงสร้างสรรค์ (Generative Adversarial Networks) และการประยุกต์ใช้ในการตรวจจับการฉ้อโกงทางการเงินในระบบธนาคาร 143

6.1 โครงข่ายปรปักษ์เชิงสร้างสรรค์.....	143
6.2 การประยุกต์ใช้โครงข่ายปรปักษ์เชิงสร้างสรรค์ในการตรวจจับการฉ้อโกง ทางการเงินในระบบธนาคาร.....	150
สรุปเนื้อหาบทที่ 6.....	161

บทที่ 7 การเรียนรู้การถ่ายโอน (Transfer Learning)..... 163

7.1 หลักการเรียนรู้การถ่ายโอน.....	163
7.2 การทำนายผลด้วยแบบจำลองที่ผ่านการเรียนรู้การถ่ายโอน	174
7.3 การประยุกต์การเรียนรู้การถ่ายโอนและการปรับแต่งแบบจำลอง สำหรับการประมวลผลภาพ.....	177
สรุปเนื้อหาบทที่ 7.....	184

บทที่ 8 การปรับใช้แบบจำลองการเรียนรู้เชิงลึกในเว็บแอปพลิเคชันด้วย Flask Framework 185

8.1 เฟรมเวิร์กฟลัสก์.....	185
---------------------------	-----

8.2 ตัวอย่างการใช้งานเฟรมเวิร์กฟลask.....	188
8.3 การประยุกต์การปรับใช้แบบจำลองการเรียนรู้เชิงลึกด้วย เฟรมเวิร์กฟลask.....	189
สรุปเนื้อหาบทที่ 8.....	205
บทที่ 9 การแสดงข้อมูลแบบจำลองการเรียนรู้เชิงลึกด้วย TensorBoard.....	207
9.1 เทนเซอร์บอร์ด.....	207
9.2 คุณสมบัติหลักของเทนเซอร์บอร์ด.....	208
9.3 การติดตั้งและการกำหนดค่าเทนเซอร์บอร์ด.....	209
9.4 ตัวอย่างการสร้างเทนเซอร์บอร์ดของการเรียนรู้เชิงลึก (Deep Learning)...	213
สรุปเนื้อหาบทที่ 9.....	221
ภาคผนวก การใช้ model.summary() และการคำนวณพารามิเตอร์ ในแบบจำลองการเรียนรู้เชิงลึก	223
บรรณานุกรม.....	228
ดัชนี	231



บทที่

1

หลักการเรียนรู้เชิงลึก (Principles of Deep Learning)

เนื้อหาในบทนี้กล่าวถึงหลักการเรียนรู้เชิงลึกซึ่งเป็นการจำลองรูปแบบการประมวลผลของสมองมนุษย์ โดยใช้โครงข่ายประสาทเทียมที่คล้ายเซลล์ประสาทในการประมวลผล กล่าวคือ เมื่อได้รับข้อมูลจะทำการแบ่งแยกข้อมูลและรายละเอียดต่างๆ ที่ได้รับมาทั้งหมด แล้วนำมาประมวลผลโดยการหาคุณลักษณะเด่น และคุณลักษณะแตกต่างของข้อมูลในเชิงลึก ซึ่งคล้ายกับวิธีการกรองข้อมูลเป็นชั้นๆ แล้วสรุปผลข้อมูลออกมาเป็นผลลัพธ์ และตรวจสอบว่าข้อมูลนั้นส่งผลอย่างไร ผิด หรือถูก เมื่อทำการสอนแบบจำลองเพื่อให้เรียนรู้ข้อมูลจำนวนมากจะทำให้การเรียนรู้เชิงลึกมีความเข้าใจข้อมูลเพิ่มมากขึ้น และลงลึกในรายละเอียดได้มากขึ้น จึงทำให้การเรียนรู้เชิงลึกสามารถคิด แยกแยะ และวิเคราะห์ได้เหมือนมนุษย์ ดังนั้นจึงมีการประยุกต์ใช้งานการเรียนรู้เชิงลึกในงานต่างๆ เช่น รถยนต์ไร้คนขับ ผู้ช่วยส่วนตัวอัจฉริยะ อาทิ สิริ (Siri) คอร์ทานา (Cortana) หรืออเล็กซ่า (Alexa) ที่สามารถค้นหาข้อมูลหรือสั่งงานต่างๆ ด้วยเสียงบนอุปกรณ์อัจฉริยะ ระบบการแปลภาษาอัตโนมัติ การรู้จำภาพ และทำนายแผ่นดินไหว




1.1 ความหมายและประเภทของการเรียนรู้เชิงลึก

ความหมายและประเภทของการเรียนรู้เชิงลึกมีดังนี้

1.1.1 ความหมายของการเรียนรู้เชิงลึก

การเรียนรู้เชิงลึก (Deep Learning : DL) เป็นหนึ่งในเทคนิคของการเรียนรู้ของเครื่อง (Machine Learning : ML) ซึ่งใช้เทคนิคโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network : DNN) สำหรับการเรียนรู้แบบอัตโนมัติ โดยเลียนแบบการทำงานของโครงข่ายประสาทในสมองมนุษย์ (Neurons) ซึ่งอัลกอริทึม (Algorithm) จะสร้างแบบจำลองที่ประกอบ

ด้วยหน่วยประมวลผลหรือโหนด (Node) จำนวนมาก ที่ทำการคำนวณในหลายชั้นและแต่ละหน่วยประมวลผลในแต่ละชั้นจะทำงานร่วมกันเพื่อเพิ่มประสิทธิภาพในการค้นหารูปแบบที่หลากหลายและซับซ้อน รวมทั้งแสดงผลลัพธ์ที่ถูกต้อง (Simon, 2023) โครงข่ายประสาทเทียมมีลักษณะการทำงานแบ่งออกเป็นชั้นต่างๆ ที่เรียกว่า เลเยอร์ (Layer) ได้แก่ ชั้นนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นแสดงผลลัพธ์ (Output Layer) ดังแสดงในรูปที่ 1.1




รูปที่ 1.1 ตัวอย่างโครงข่ายประสาทเทียม (Artificial Neural Network) อย่างง่าย

จากรูปที่ 1.1 ตัวอย่างโครงข่ายประสาทเทียม (Artificial Neural Network) อย่างง่าย ประกอบด้วย 3 ชั้น ได้แก่ ชั้นนำเข้า (Input Layer) ซึ่งเป็นชั้นแรกที่น่าำข้อมูลเข้าสู่ระบบ จากรูปชั้นนำเข้าประกอบด้วย 3 โหนด ซึ่งจำนวนโหนดในชั้นนำเข้าขึ้นอยู่กับจำนวนคุณลักษณะ (Features) ของข้อมูล เช่น ข้อมูลคอนโดมิเนียมมีจำนวน 3 คุณลักษณะ ได้แก่ ขนาดพื้นที่ จำนวนห้องนอน และทำเล ดังนั้นจึงทำให้จำนวนโหนดของชั้นนำเข้ามีจำนวน 3 โหนดตามคุณลักษณะของข้อมูล และส่งต่อไปยังชั้นซ่อน (Hidden Layer) ซึ่งเป็นชั้นที่สองที่ทำหน้าที่แปลงข้อมูล และวิเคราะห์ข้อมูลจากชั้นนำเข้า โดยจำนวนโหนดของชั้นซ่อนแปรผันตามความซับซ้อนของปัญหา (ซึ่งไม่มีจำนวนโหนดที่แน่นอนและตายตัว แต่สามารถปรับเปลี่ยนจำนวนโหนดได้จากการวัดค่าประสิทธิภาพของแบบจำลอง) และจากนั้นจะส่งผลต่อไปยังชั้นผลลัพธ์ (Output Layer) ซึ่งเป็นชั้นสุดท้าย สำหรับแสดงผลลัพธ์ตามโจทย์ปัญหา ซึ่งในตัวอย่างมีจำนวน 2 โหนด กล่าวคือถ้าเป็นโจทย์ปัญหาของการจำแนกประเภท (Classification) จำนวน 2 โหนดจะหมายถึงการจำแนกคลาสเป็น 2 คลาส เช่น ชื้อคอนโด หรือไม่ซื้อคอนโด เป็นต้น

1.1.2 ประเภทการเรียนรู้เชิงลึก

การเรียนรู้เชิงลึกมีหลายประเภทที่แตกต่างกัน ขึ้นอยู่กับลักษณะและวิธีการของการเรียนรู้ โดยหลักๆ แล้วสามารถแบ่งประเภทได้ 3 ประเภท ได้แก่ การเรียนรู้แบบมีผู้สอน (Supervised Learning) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) และการเรียนรู้แบบเสริมแรง (Reinforcement Learning) (Francois, 2021) ดังแสดงในรูปที่ 1.2



รูปที่ 1.2 ประเภทการเรียนรู้เชิงลึก

1. การเรียนรู้แบบมีผู้สอน (Supervised Learning) ซึ่งโครงข่ายประสาทเทียมจะเรียนรู้จากข้อมูลที่มีการติดป้าย (Labeled Data) เพื่อทำนายหรือจำแนกประเภท โดยอัลกอริทึมที่ได้รับความนิยม เช่น การรับรู้หลายระดับชั้น (Multi-Layer Perceptron : MLP) โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network : CNN) หรือโครงข่ายประสาทเทียมวนซ้ำ (Recurrent Neural Network : RNN) ซึ่งถูกนำไปประยุกต์ใช้งานต่างๆ เช่น การจดจำภาพใบหน้า (Face Recognition) และการแปลภาษา (Language Translation)


2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งโครงข่ายประสาทเทียมจะหาความสัมพันธ์หรือรูปแบบในข้อมูลที่ไม่มีการติดป้าย (Unlabeled Data) โดยอัลกอริทึมที่ได้รับความนิยม เช่น ออโตเอนโค้ดเดอร์ (Autoencoders) เจเนอเรทีฟ แอดเวอร์ซารี เน็ตเวิร์ก (Generative Adversarial Network : GAN) หรือเซลฟ์-ออร์แกไนซิงแมป (Self-Organizing Maps : SOM) ซึ่งถูกนำไปประยุกต์ใช้งานต่างๆ เช่น การจัดกลุ่ม (Clustering) และการตรวจจับความผิดปกติ (Anomaly Detection)

3. การเรียนรู้แบบเสริมแรง (Reinforcement Learning) ตัวแทน (Agent) ทำการเรียนรู้ที่จะตัดสินใจโดยการเพิ่มรางวัลสูงสุด (Maximizing Rewards) โดยอัลกอริทึมที่ได้รับความนิยม เช่น ดีปคิวเน็ตเวิร์ก (Deep Q Network : DQN) ดีป ดีเทอร์มินิสติก โพลีซี เกรเดียนต์ (Deep Deterministic Policy Gradient : DDPG) หรือพรอกซิมอล โพลีซี อ็อปติไมเซชัน (Proximal Policy Optimization : PPO) ซึ่งถูกนำไปใช้ในงานต่างๆ เช่น หุ่นยนต์ (Robotics) และการเล่นเกม (Game Playing)



1.2 ความสัมพันธ์ระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

จากที่กล่าวมาการเรียนรู้เชิงลึกเป็นสาขาหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งทำหน้าที่ประมวลผลข้อมูลที่มีโครงสร้างซับซ้อนหลายระดับ เช่น การรู้จำเสียง การรู้จำภาพ การรู้จำวิดีโอ การวิเคราะห์ข้อความ หรือการแปลภาษา หลักการของการเรียนรู้เชิงลึกคือ การใช้ข้อมูลจำนวนมากเพื่อสร้างความสัมพันธ์ระหว่างข้อมูล จากนั้นคำนวณหาค่าน้ำหนักที่เหมาะสมตามหลักการทางคณิตศาสตร์ สถิติ และการทำเหมืองข้อมูล (Data Mining) ทั้งในด้านการสกัดข้อมูล (Data Extraction) การค้นพบรูปแบบที่ซ่อนอยู่ (Discovering Hidden Patterns) และการวิเคราะห์เชิงทำนาย (Predictive Analytics) เพื่อทำให้เกิดการเรียนรู้ด้วยตนเองที่มีความถูกต้องและมีประสิทธิภาพ ซึ่งคล้ายกับการทำงานของระบบประสาทที่ซับซ้อนของสมองมนุษย์ ดังแสดงในรูปที่ 1.3



รูปที่ 1.3 ความสัมพันธ์ระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

จากรูปที่ 1.3 แสดงความสัมพันธ์ระหว่างปัญญาประดิษฐ์ (Artificial Intelligence : AI) การเรียนรู้ของเครื่อง (Machine Learning : ML) และการเรียนรู้เชิงลึก (Deep Learning : DL) โดยปัญญาประดิษฐ์หมายถึงความสามารถของเครื่องจักรหรือคอมพิวเตอร์ในการเลียนแบบพฤติกรรมและความสามารถทางปัญญาของมนุษย์ เช่น การตัดสินใจ การวางแผน และการแก้ไขปัญหา โดย AI ครอบคลุมทุกเทคโนโลยีที่ทำให้คอมพิวเตอร์สามารถทำงานได้เหมือนมนุษย์ ภายใน AI ประกอบด้วยการเรียนรู้ของเครื่อง ซึ่งเป็นสาขาหนึ่งของ AI ที่มุ่งเน้นความสามารถของคอมพิวเตอร์ในการเรียนรู้จากชุดข้อมูล (Data Sets) จำนวนมาก ซึ่งนำมาฝึกฝนให้เรียนรู้รูปแบบข้อมูลและทำนายผลลัพธ์โดยอัตโนมัติ (วฤษาย, 2566)

สำหรับการเรียนรู้เชิงลึกเป็นสาขาย่อยของการเรียนรู้ของเครื่องที่มีการทำงานในลักษณะเดียวกัน โดยใช้แนวคิดในการจัดจํารูปแบบข้อมูลที่เรียนรู้มาแล้วก่อน จากนั้นจึงสามารถระบุ

รูปแบบข้อมูลได้ จุดเด่นสำคัญของการเรียนรู้เชิงลึกคือการค้นหาคุณลักษณะสำคัญ (Feature) ของข้อมูลได้โดยอัตโนมัติ ในขณะที่การเรียนรู้ของเครื่องจะเลือกเฉพาะคุณลักษณะสำคัญ (Feature Selection) ด้วยตนเอง ซึ่งต้องการการประมวลผลเพิ่มเติม นอกจากนี้การเรียนรู้เชิงลึกยังใช้โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) ที่มีหลายระดับชั้นระหว่างข้อมูลเข้าและข้อมูลออก หรือที่เรียกว่าชั้นซ่อน (Hidden Layer) หลายชั้น เพื่อเพิ่มประสิทธิภาพในการประมวลผลที่ซับซ้อนและให้ผลลัพธ์ที่มีความถูกต้อง



1.3 กระบวนการทำงานของการเรียนรู้เชิงลึก

กระบวนการทำงานของการเรียนรู้เชิงลึกเป็นการนำข้อมูลเข้า เช่น รูปภาพ วิดีโอ หรือ ไฟล์เสียง เข้าสู่การสร้างแบบจำลองการเรียนรู้เชิงลึกซึ่งประกอบด้วย 2 ส่วนหลักได้แก่ การเลือกคุณลักษณะ (Feature Selection) และการจำแนกประเภท (Classification) และการแสดงผลลัพธ์ ดังแสดงในรูปที่ 1.4



รูปที่ 1.4 กระบวนการทำงานของการเรียนรู้เชิงลึก

ดัดแปลงจาก : <https://builtin.com/machine-learning/deep-learning>

จากรูปที่ 1.4 กระบวนการทำงานของการเรียนรู้เชิงลึก จากตัวอย่างเมื่อนำเข้าข้อมูลไฟล์ภาพรถยนต์ จากนั้นจะเข้าสู่การสร้างแบบจำลองการเรียนรู้เชิงลึกที่ดำเนินการสกัดคุณลักษณะ และการจัดประเภทในขั้นตอนเดียวกันและดำเนินการแบบอัตโนมัติ ซึ่งไม่จำเป็นต้องดำเนินการทำวิศวกรรมคุณลักษณะ (Feature Engineering) ด้วยมนุษย์ โดยชั้นของโครงข่ายประสาทเทียมจะเรียนรู้ลำดับชั้นของคุณลักษณะเอง เช่น ชั้นแรกเรียนรู้ขอบ (Edges) และสี ชั้นกลางเรียนรู้รูปร่าง (Shapes) และรูปแบบ (Patterns) และชั้นสุดท้ายเรียนรู้ลักษณะที่ซับซ้อน เช่น ไฟหนัารถ หรือล้อรถ และการทำนายผล (Prediction) โดยแบบจำลองจะทำการจัดประเภท (Classification) โดยตรง และให้ผลลัพธ์ว่าเป็น “รถยนต์” หรือ “ไม่ใช่รถยนต์” เป็นต้น

หมายเหตุ จะเห็นได้ว่ากระบวนการทำงานของการเรียนรู้เชิงลึกมีความแตกต่างจากกระบวนการทำงานของการเรียนรู้ของเครื่องที่ต้องการการเลือกคุณลักษณะโดยมนุษย์ก่อน จากนั้นจึงนำไปจัดประเภทด้วยแบบจำลอง ซึ่งกระบวนการทำงานของการเรียนรู้เชิงลึกจะเรียนรู้คุณลักษณะเองจากข้อมูลดิบ โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้นและทำการจัดประเภทได้อย่างแม่นยำมากขึ้น



1.4 ตัวอย่างอัลกอริทึมการเรียนรู้เชิงลึก

เนื้อหาในประเด็นนี้ขอยกตัวอย่างอัลกอริทึมของการเรียนรู้เชิงลึกที่ได้รับความนิยมและถูกนำไปประยุกต์ใช้งานในด้านต่างๆ จำนวนมาก รายละเอียดดังนี้

1. การรับรู้หลายระดับชั้น (Multi-Layer Perceptron : MLP) เป็นอัลกอริทึมที่ประกอบไปด้วยหลายชั้น (Layers) ซึ่งประกอบด้วย 3 ส่วนหลัก ได้แก่ ชั้นนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และ ชั้นผลลัพธ์ (Output Layer) โดยที่ข้อมูลจะถูกส่งผ่านจากชั้นหนึ่งไปยังอีกชั้นหนึ่ง โดยในแต่ละชั้นจะมีการใช้ ฟังก์ชันกระตุ้น (Activation Function) เพื่อปรับค่าผลลัพธ์ก่อนที่จะส่งไปยังชั้นถัดไป ตัวอย่างนำไปประยุกต์ใช้งานด้านต่างๆ เช่น การจำแนกข้อมูลภาพ (Image Classification) การจำแนกข้อความ (Text Classification) การทำนายราคาหุ้น (Stock Price Prediction) การทำนายราคาบ้าน (House Price Prediction) การตรวจจับการฉ้อโกง (Fraud Detection) หรือการรู้จำคำสั่งเสียง (Voice Command Recognition)

2. โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network : CNN) เป็นอัลกอริทึมที่ออกแบบมาเพื่อประมวลผลข้อมูลที่มีโครงสร้างเป็นกริด¹ ตัวอย่างนำไปประยุกต์ใช้งานด้านต่างๆ เช่น การจำแนกภาพ (Image Classification) การตรวจจับวัตถุ (Object Detection) การรู้จำใบหน้า (Face Recognition) การประมวลผลวิดีโอ (Video Processing) การพัฒนารถยนต์อัตโนมัติ (Autonomous Vehicles) หรือการวิเคราะห์เสียง (Audio Analysis)

3. โครงข่ายประสาทเทียมวนซ้ำ (Recurrent Neural Network : RNN) เป็นอัลกอริทึมที่ถูกออกแบบมาเพื่อจดจำรูปแบบในข้อมูลลำดับ (Sequence Data) เช่น ข้อมูลอนุกรมเวลา (Time Series) หรือภาษาธรรมชาติ (Natural Language) โดยมีสถานะซ่อน (Hidden State) ที่จดจำข้อมูลจากอินพุตก่อนหน้าได้ แต่มีข้อจำกัดในการเรียนรู้ระยะยาว ตัวอย่างนำไปประยุกต์ใช้งานด้านต่างๆ เช่น การแปลภาษา (Machine Translation) การรู้จำเสียงพูด (Speech Recognition) การสรุปข้อความ (Text Summarization) การทำนายราคาหุ้น (Stock Price Prediction) การรู้จำวิดีโอหรือกิจกรรมในภาพ (Video and Activity Recognition) หรือการรู้จำเสียง (Audio Recognition)

4. หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) เป็นอัลกอริทึมประเภทหนึ่งของโครงข่ายประสาทเทียมวนซ้ำหรือ RNN ที่ออกแบบมาเพื่อแก้

¹ โครงสร้างเป็นกริด (Grid Structure) หมายถึง รูปแบบการจัดเรียงข้อมูลที่เป็นตารางหรือเมทริกซ์ (Matrix) ซึ่งมีแถว (Rows) และคอลัมน์ (Columns)

ปัญหาการลืมนข้อมูลระยะยาว (Long-Term Dependency Problem) โดยเหมาะกับงานที่ต้องจดจำข้อมูลในลำดับที่ยาว เช่น การรู้จำเสียงพูด (Speech Recognition) หรือการพยากรณ์อนุกรมเวลา (Time Series Prediction) ตัวอย่างนำไปประยุกต์ใช้งานด้านต่าง ๆ เช่น การแปลภาษา (Machine Translation) การรู้จำเสียงพูด (Speech Recognition) การสรุปข้อความ (Text Summarization) การทำนายราคาหุ้น (Stock Price Prediction) หรือการรู้จำวิดีโอหรือกิจกรรมในภาพ (Video and Activity Recognition)

5. ออโตเอนโค้ดเดอร์ (Autoencoders) เป็นแบบจำลองประเภทการเรียนรู้แบบไม่มีผู้สอนที่ใช้วิธีการบีบอัดและกู้คืนข้อมูล โดยเรียนรู้การเข้ารหัสข้อมูลเป็นตัวแทนที่มีมิติที่ต่ำกว่า (Latent Space) และถอดรหัสกลับมาให้ใกล้เคียงกับต้นฉบับ ตัวอย่างนำไปประยุกต์ใช้งานด้านต่าง ๆ เช่น การลดมิติ (Dimensionality Reduction) การบีบอัดข้อมูล (Data Compression) การตรวจจับความผิดปกติ (Anomaly Detection) การสร้างข้อมูลใหม่ (Data Generation) หรือการแนะนำ (Recommendation Systems)

6. เจเนอเรทีฟ แอดเวอร์ซารีเน็ตเวิร์ก (Generative Adversarial Network : GAN) เป็นอัลกอริทึมที่ประกอบด้วย 2 โครงข่ายประสาทเทียมที่มีการแข่งขันกัน โดยประกอบด้วยผู้สร้างข้อมูลปลอม (Generator) และผู้แยกแยะข้อมูลจริงกับปลอม (Discriminator) (Sudharsan Ravichandiran, 2019) ผู้สร้างข้อมูลปลอมจะพยายามหลอกผู้แยกแยะข้อมูลจริงกับปลอม และผู้แยกแยะข้อมูลจริงกับปลอมจะพัฒนาตัวเองให้แยกแยะข้อมูลได้แม่นยำมากยิ่งขึ้น ตัวอย่างนำไปประยุกต์ใช้งานด้านต่าง ๆ เช่น การสร้างภาพ (Image Generation) การปรับแต่งภาพ (Image Editing and Enhancement) การสร้างวิดีโอ (Video Generation) การสร้างเสียงและดนตรี (Sound and Music Generation) การสร้างตัวละครหรือภาพใบหน้า (Face Generation) หรือการสร้างข้อความ (Text Generation)

7. ทรานส์ฟอร์เมอร์ (Transformer) เป็นโครงสร้างพื้นฐานของแบบจำลองการประมวลผลภาษาธรรมชาติ (Natural Language Processing : NLP) เช่น แชตจีพีที (ChatGPT) โดยใช้ Self-Attention Mechanism เพื่อวิเคราะห์ความสัมพันธ์ของทุกคำในประโยคได้พร้อมกัน และประมวลผลข้อมูลได้อย่างขนาน (Parallelization) ตัวอย่างนำไปประยุกต์ใช้งานด้านต่าง ๆ เช่น การแปลภาษา (Machine Translation) การสรุปข้อความ (Text Summarization) การทำความเข้าใจความหมาย (Question Answering) การสร้างข้อความ (Text Generation) การสร้างภาพจากข้อความ (Text-to-Image Generation) หรือการสร้างวิดีโอจากข้อความ (Text-to-Video)

รายละเอียดหลักการทำงานและตัวอย่างการประยุกต์ใช้งานของแต่ละอัลกอริทึมจะกล่าวถึงในบทต่อไป



1.5 เครื่องมือสำหรับการเรียนรู้เชิงลึก

เครื่องมือสำหรับการเรียนรู้เชิงลึกที่ใช้ในการพัฒนา ฝึกสอน และทดสอบแบบจำลอง สำหรับการประมวลผลข้อมูลขนาดใหญ่ที่มีความซับซ้อน เช่น ข้อมูลภาพ เสียง หรือข้อความ ในที่นี้ขอยกตัวอย่างเครื่องมือสำหรับการเรียนรู้เชิงลึกที่ได้รับความนิยมมา 6 ตัวอย่าง (กอบเกียรติ, 2565) รายละเอียดดังต่อไปนี้

1. เทนเซอร์โฟลว์ (TensorFlow) เป็นเครื่องมือที่พัฒนาโดยกูเกิล (Google) และเป็นหนึ่งในไลบรารีการเรียนรู้เชิงลึกที่ได้รับความนิยมสูงสุด มีความยืดหยุ่นและสามารถรองรับการประมวลผลทั้ง CPU, GPU และ TPU

2. ไพทอร์ช (PyTorch) พัฒนาโดย Facebook AI Research (FAIR) เป็นเครื่องมือที่ได้รับความนิยมในวงการวิจัยและการพัฒนาแบบจำลองการเรียนรู้เชิงลึก เนื่องจากมีความยืดหยุ่นสูงและเหมาะสมสำหรับการทดลองใหม่ ๆ เช่น การคำนวณกราฟที่มีความยืดหยุ่นสูง (Dynamic Computation Graph) และรองรับการประมวลผลกราฟิก (GPU Acceleration) สำหรับการฝึกสอนแบบจำลองที่เร็วขึ้น

3. เคอร์ส (Keras) เป็นไลบรารีที่ใช้งานง่ายและเป็นที่ยอมรับสำหรับการสร้างแบบจำลองการเรียนรู้เชิงลึก โดยใช้เทนเซอร์โฟลว์ (TensorFlow) เป็นพื้นฐาน (ซึ่งในปัจจุบันนี้ Keras รวมอยู่ในเทนเซอร์โฟลว์) และรองรับการสร้างแบบจำลองหลายประเภท เช่น โครงข่ายประสาทเทียมคอนโวลูชัน (CNN) โครงข่ายประสาทเทียมวนซ้ำ (RNN) หน่วยความจำระยะสั้นแบบยาว (LSTM) และเจนเนอเรทีฟ แอดเวอร์ซารี เน็ตเวิร์ก (GAN)

4. คาเฟ (Caffe) เป็นเครื่องมือที่เหมาะสมสำหรับการพัฒนาและฝึกสอนแบบจำลองการเรียนรู้เชิงลึก ในงานที่เกี่ยวข้องกับภาพ (Computer Vision) โดยเฉพาะเพิ่มความเร็วในการฝึกสอนแบบจำลองให้เหมาะกับการใช้งานในสภาพแวดล้อมที่ต้องการประสิทธิภาพสูง โดยเฉพาะรองรับการสร้างแบบจำลองด้วยอัลกอริทึม CNN ได้ดี

5. ฮักกิง เฟซ ทรานส์ฟอร์มเมอร์ (Hugging Face Transformer) เครื่องมือที่เน้นการประมวลผลตามหลักการประมวลผลภาษาธรรมชาติ (Natural Language Processing : NLP) โดยเฉพาะ ซึ่งมีแบบจำลองที่ได้รับการฝึกสอนมาแล้วจำนวนมาก เช่น BERT, GPT, T5 หรือ RoBERTa

6. โอเพนซีวี (Open Source Computer Vision Library : OpenCV) เป็นไลบรารีที่ใช้สำหรับการประมวลผลภาพและคอมพิวเตอร์วิทัศน์ (Computer Vision) โดยมีการรวมฟังก์ชันที่มีความหลากหลาย เช่น การตรวจจับใบหน้า การแยกวัตถุ และการติดตาม



1.6 ชุดข้อมูลมาตรฐานของการเรียนรู้เชิงลึก

ชุดข้อมูลมาตรฐานของการเรียนรู้เชิงลึกที่ถูกนำไปใช้อย่างแพร่หลายในการวิจัยและการพัฒนาแบบจำลองต่างๆ เช่น การจำแนกภาพ การแปลภาษา และการประมวลผลเสียง โดยในที่นี้ขอยกตัวอย่างชุดข้อมูล 5 ชุดข้อมูล ดังรายละเอียดต่อไปนี้

1. MNIST (Modified National Institute of Standards and Technology)

เป็นชุดข้อมูลภาพขนาด 28×28 พิกเซล (Pixel) ประกอบด้วย 60,000 ตัวอย่างสำหรับการฝึกสอนแบบจำลอง (Training) และ 10,000 ตัวอย่างสำหรับการทดสอบแบบจำลอง (Testing) เพื่อใช้ในการจำแนกข้อมูลตัวเลข 0–9 ดังแสดงในรูปที่ 1.5


	image	label
0		4
1		1
2		0
3		7
4		8
5		1
6		2
7		7
8		1
9		6

รูปที่ 1.5 ตัวอย่างชุดข้อมูล MNIST

ที่มา : <https://www.tensorflow.org/datasets/catalog/mnist>

2. CIFAR-10 (Canadian Institute For Advanced Research) เป็นชุดข้อมูล

ภาพขนาด 32×32 พิกเซล ประกอบด้วย 10 คลาส (Classes) เช่น เครื่องบิน (airplane) รถยนต์ (automobile) นก (bird) แมว (cat) กวาง (deer) หมา (dog) กบ (frog) ม้า (horse) เรือ (ship) และรถบรรทุก (truck) โดยชุดข้อมูลนี้ประกอบด้วยภาพจำนวน 60,000 ภาพ (ซึ่ง 50,000 ภาพสำหรับการฝึกสอนแบบจำลอง และ 10,000 ภาพสำหรับการทดสอบแบบจำลอง) ดังแสดงในรูปที่ 1.6



รูปที่ 1.6 ตัวอย่างชุดข้อมูล CIFAR-10

ที่มา : <https://www.cs.toronto.edu/~kriz/cifar.html>


3. ImageNet เป็นชุดข้อมูลภาพจำนวนมากกว่า 14 ล้านภาพ ซึ่งประกอบด้วยภาพจำนวน 21,000 คลาส มีความละเอียดสูงและใช้ในการฝึกสอนแบบจำลองการจำแนกภาพ ดังแสดงในรูปที่ 1.7



รูปที่ 1.7 ตัวอย่างชุดข้อมูล ImageNet

ที่มา : <https://www.image-net.org/update-mar-11-2021.php>

4. COCO (Common Objects in Context) เป็นชุดข้อมูลที่มีภาพมากกว่า 300,000 ภาพ ที่มีการติดป้ายกำกับกับข้อมูลซึ่งประกอบด้วยข้อมูลภาพต่างๆ เช่น คน สุนัข หรือรถ เป็นต้น โดยชุดข้อมูลนี้มีการตรวจจับวัตถุ (Object Detection) การแบ่งภาพ (Segmentation) และการแสดงคำบรรยาย (Captioning) ดังแสดงในรูปที่ 1.8



รูปที่ 1.8 ตัวอย่างชุดข้อมูล COCO

ที่มา : <https://docs.ultralytics.com/datasets/detect/coco/#sample-images-and-annotations>

5. LibriSpeech เป็นชุดข้อมูลเสียงที่ใช้สำหรับการรู้จำเสียงพูด (Speech Recognition) ประกอบด้วยคลิปเสียงจากหนังสือที่อ่านโดยนักพูดต่างๆ โดยชุดข้อมูลนี้ประกอบด้วยเสียงพูดที่มีการถอดความประมาณ 1,000 ชั่วโมง



1.7 ตัวอย่างการประยุกต์การเรียนรู้เชิงลึก

เนื้อหาในเรื่องนี้ขอตัวอย่างการเรียนรู้เชิงลึกมา 5 ตัวอย่าง ได้แก่ รถยนต์ขับเคลื่อนอัตโนมัติ (Autonomous Vehicles) การวินิจฉัยโรค (Diagnosis) การแปลภาษา (Language Translation) ปฏิสัมพันธ์ระหว่างมนุษย์กับคอมพิวเตอร์ (Human-computer Interaction) และแอลฟาโกะ (AlphaGo) รายละเอียดดังนี้

1. รถยนต์ขับเคลื่อนอัตโนมัติ (Autonomous Vehicles) เป็นการสร้างระบบความปลอดภัยของรถยนต์ในปัจจุบันอย่างระบบควบคุมความเร็ว ระบบเบรกอัตโนมัติ หรือระบบเตือนเมื่อรถออกนอกเลน ซึ่งใช้หลักการการเรียนรู้เชิงลึกในการแยกวัตถุที่อยู่รอบรถยนต์ไม่ว่าจะเป็นรถยนต์คันอื่น รถจักรยานยนต์ จักรยาน สัญญาณไฟจราจร ป้ายจราจร หรือคนเดินถนน ผ่านการดึงข้อมูลจากเซนเซอร์และกล้องจำนวนมากภายในรถยนต์ และนำมาคำนวณเพื่อหาทิศทาง ความเร็วที่เหมาะสม หรือการอ่านข้อมูลจากป้ายเตือนต่างๆ และสั่งให้รถยนต์ลดความเร็ว หรือหยุดได้ด้วยตนเอง

2. การวินิจฉัยโรค (Diagnosis) โดยการเรียนรู้เชิงลึกถูกนำมาเป็นเครื่องมือในการวินิจฉัยโรค เช่น การวินิจฉัยจากข้อมูลส่วนตัวของผู้ป่วยอย่างน้ำหนัก ส่วนสูง ค่าน้ำตาลในเลือดหรือค่าไขมันในเลือด เพื่อหาสาเหตุของอาการเจ็บป่วย หรือการวินิจฉัยจากภาพถ่ายทางการแพทย์ เช่น ภาพเอกซเรย์ ภาพอัลตราซาวด์หรือภาพจากเครื่องตรวจคลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging : MRI) ซึ่งการเรียนรู้เชิงลึกจะประมวลผลภาพถ่ายของ

ผู้ป่วยโดยเปรียบเทียบกับฐานข้อมูลภาพ เพื่อค้นหาความผิดปกติอย่างเนื้องอกหรือมะเร็ง และระบุตำแหน่งของความผิดปกติที่เกิดขึ้นกับอวัยวะให้แพทย์ได้ทราบ ซึ่งช่วยลดเวลาในการวินิจฉัยโรคของแพทย์ เพิ่มความถูกต้อง และแม่นยำในการรักษาคนไข้

3. การแปลภาษา (Language Translation) เช่น Google Translate ใช้หลักการพื้นฐานของการเรียนรู้เชิงลึก 2 ขั้นตอน ได้แก่ การวิเคราะห์ข้อมูลที่ใช้งานป้อนเข้า ในรูปของตัวอักษร รูปภาพ และเสียง เพื่อเปรียบเทียบข้อมูลที่ถูกป้อนกับฐานข้อมูลคำ ที่มีหลากหลายภาษา และการแปลเพื่อหาความหมายที่เหมาะสมที่สุดสำหรับคำที่ต้องการ

4. ปฏิสัมพันธ์ระหว่างมนุษย์กับคอมพิวเตอร์ (Human-computer Interaction) การเรียนรู้เชิงลึกสามารถนำมาใช้ในการสร้างการโต้ตอบ เช่น การโต้ตอบกับข้อมูลที่ใช้ส่งเข้าไปยังบริการโต้ตอบอัตโนมัติอย่าง Siri (Siri) อเล็กซา (Alexa) และกูเกิลแอสซิสแทนต์ (Google Assistant) หรือการสร้างงานที่ต้องการทักษะในการเขียนสูง เช่น การเขียนนวนิยายหรือบทความวิชาการ ซึ่งการเรียนรู้เชิงลึกสามารถหาความเชื่อมโยงระหว่างคำหรือประโยคที่มีอยู่ในฐานข้อมูล และนำคำที่เกี่ยวข้องเหล่านี้มาสร้างเป็นประโยคหรือย่อหน้าที่มีความหมายสมบูรณ์

5. แอลฟาโกะ (AlphaGo) เมื่อปี ค.ศ. 2016 มีการแข่งขันหมากล้อมระหว่างนักหมากล้อมแชมป์โลกชาวเกาหลีใต้กับคอมพิวเตอร์ชื่อว่า แอลฟาโกะ (AlphaGo) ที่ใช้การเรียนรู้เชิงลึกในการวิเคราะห์และดำเนินเกม ด้วยความสามารถของการเรียนรู้เชิงลึกที่พลิกแพลงการวางหมากได้อย่างถูกต้องและแม่นยำ ทำให้แอลฟาโกะสามารถเอาชนะมนุษย์ได้ถึง 4-1 เกม ในปัจจุบัน แอลฟาโกะถูกพัฒนาต่อยอดเป็นแอลฟาโกะมาสเตอร์ (AlphaGo Master) แอลฟาโกะซีโร (AlphaGo Zero) และแอลฟาซีโร (Alphazero) ที่มีความสามารถเพิ่มมากขึ้น



1.8 การเตรียมสภาพแวดล้อมและการจัดการข้อมูลขนาดใหญ่


การเตรียมสภาพแวดล้อมและการจัดการข้อมูลขนาดใหญ่สำหรับวิเคราะห์และสร้างแบบจำลองการเรียนรู้เชิงลึกประกอบด้วย 3 ส่วนสำคัญได้แก่ (1) การเปลี่ยนรันไทม์ (Runtime) จาก CPU เป็น GPU เพื่อเพิ่มประสิทธิภาพในการคำนวณที่รวดเร็ว (2) การเรียกใช้ชุดข้อมูลที่จัดเก็บไว้ที่กูเกิลไดรฟ์ (Google Drive) จากกูเกิลโคแลบ (Google Colab) และ (3) การเรียกใช้ชุดข้อมูลผ่าน API (Application Program Interface) หรือส่วนต่อประสานโปรแกรมประยุกต์

1.8.1 การเปลี่ยน Runtime เป็น GPU


การเปลี่ยน Runtime เป็น GPU มีรายละเอียดดังนี้

1. การเปลี่ยน Runtime เป็น GPU เมื่อใช้กูเกิลโคแลบในการพัฒนาแบบจำลองตามหลักการเรียนรู้เชิงลึก สามารถปรับเปลี่ยน Runtime จาก CPU เป็น GPU ได้ที่เมนูของกูเกิลโคแลบโดยดำเนินการดังต่อไปนี้


- (1) ที่เมนู Runtime
- (2) เลือกเมนูย่อย Change runtime type
- (3) ดำเนินการคลิกเปลี่ยนจาก CPU เป็น T4 GPU จากนั้นกดปุ่ม Save



(ก) ในกูเกิลโคแลบเลือกเมนู Runtime แล้วเลือก Change runtime type



(ข) ส่วนของ Hardware accelerator จะแสดงอยู่ที่ CPU



(ค) เลือกจาก CPU เป็น T4 GPU แล้วเลือกคลิก Save

รูปที่ 1.9 การเปลี่ยน Runtime จาก CPU เป็น GPU ที่กูเกิลโคแลบ

จากรูปที่ 1.9 การเปลี่ยน Runtime จาก CPU เป็น GPU ที่กูเกิลโคแลบโดยไปที่เมนู Runtime จากนั้นเลือกเมนูย่อย Change runtime type ดังรูปที่ 1.9 (ก) และรูปที่ 1.9 (ข) ดำเนินการคลิกเปลี่ยนจาก CPU เป็น T4 GPU จากนั้นกดปุ่ม Save ดังรูปที่ 1.9 (ค)


2. การเขียนคำสั่งสำหรับตรวจสอบ Runtime เป็น GPU ด้วยเทนเซอร์โฟลว์ (TensorFlow) หรือไพทอร์ช (PyTorch) ซึ่งในการเขียนคำสั่งภาษาไพธอนสำหรับตรวจสอบ GPU สามารถเลือกใช้วิธีการเขียนคำสั่งด้วยเทนเซอร์โฟลว์ หรือไพทอร์ชอย่างใดอย่างหนึ่งได้ดังตัวอย่างต่อไปนี้

ตัวอย่างคำสั่งตรวจสอบ Runtime เป็น GPU ด้วยเทนเซอร์โฟลว์

บรรทัดที่	โปรแกรม
1	import tensorflow as tf #การนำเข้าไลบรารี TensorFlow
2	device_name = tf.test.gpu_device_name() #การตรวจสอบว่าเครื่องของคุณมี GPU และสามารถเข้าถึงได้หรือไม่
3	if device_name != '/device:GPU:0': #ใช้ GPU ตัวแรก
4	print('GPU device not found')
5	else:
6	print(f'Found GPU at : {device_name}')

ผลลัพธ์

Found GPU at : /device:GPU:0 ดังแสดงในรูปที่ 1.10



```

Verify GPU usage with TensorFlow

[1] import tensorflow as tf
    device_name = tf.test.gpu_device_name()
    if device_name != '/device:GPU:0':
        print('GPU device not found')
    else:
        print(f'Found GPU at: {device_name}')

Found GPU at: /device:GPU:0
  
```

รูปที่ 1.10 การแสดงผลลัพธ์จากการตรวจสอบ Runtime เป็น GPU ด้วยเทนเซอร์โฟลว์

จากรูปที่ 1.10 ผลลัพธ์แสดงว่าเทนเซอร์โฟลว์พบ GPU และสามารถใช้งานได้ ซึ่งจะทำให้เครื่องที่ใช้ทำงานสามารถใช้ GPU เพื่อเร่งความเร็วในการคำนวณได้ และ /device:GPU:0 หมายถึงการระบุที่อยู่ของ GPU ตัวแรกในระบบของเทนเซอร์โฟลว์ (TensorFlow)

ตัวอย่างคำสั่งตรวจสอบ Runtime เป็น GPU ด้วยไพทอร์ช (PyTorch)

บรรทัดที่	โปรแกรม
1	import torch #การนำเข้าไลบรารี PyTorch
2	if torch.cuda.is_available(): #การตรวจสอบว่า CUDA (ที่ใช้ในการทำงานกับ GPU) พร้อมใช้งานหรือไม่
3	print(f"CUDA is available. Device name : {torch.cuda.get_device_name(0)}")
4	else:
5	print("CUDA is not available. Using CPU.")

ผลลัพธ์

CUDA is available. Device name : Tesla T4 ดังแสดงในรูปที่ 1.11



```

Verify GPU usage with PyTorch

[2] import torch
    if torch.cuda.is_available():
        print(f"CUDA is available. Device name: {torch.cuda.get_device_name(0)}")
    else:
        print("CUDA is not available. Using CPU.")

CUDA is available. Device name: Tesla T4

```

รูปที่ 1.11 การแสดงผลลัพธ์จากการตรวจสอบ Runtime เป็น GPU ด้วยไพทอร์ช (PyTorch)

จากรูปที่ 1.11 แพลตฟอร์ม CUDA (Compute Unified Device Architecture) เป็นแพลตฟอร์มการประมวลผลแบบขนาน (Parallel Processing)² และ API ที่พัฒนาโดยบริษัทเอ็นวีเดีย (NVIDIA) ซึ่งช่วยให้ซอฟต์แวร์สามารถใช้ความสามารถจากการประมวลผลของ GPU (Graphics Processing Unit) เพื่อเร่งความเร็วในการคำนวณต่างๆ ได้ จากผลลัพธ์แสดงว่ารุ่นของ GPU ที่พร้อมพร้อมใช้งานในระบบคือ Tesla T4 ซึ่งเป็น GPU สำหรับศูนย์ข้อมูล ที่ออกแบบโดยเอ็นวีเดียนิยมใช้ในบริการคลาวด์ เช่น กูเกิลคลาวด์ (Google Cloud) หรือ

² การประมวลผลแบบขนาน (Parallel Processing) ที่มีการประมวลผลข้อมูลหลายๆ ชุดพร้อมกันโดยใช้หลายหน่วยประมวลผล (Processors) หรือหลายอุปกรณ์ เช่น CPU หรือ GPU แทนการประมวลผลทีละชุดทีละชุด ซึ่งจะช่วยให้สามารถทำงานได้เร็วขึ้นและมีประสิทธิภาพมากขึ้น โดยเฉพาะในงานที่มีการคำนวณที่ซับซ้อนหรือมีข้อมูลจำนวนมาก

แอมะซอนเว็บเซอร์วิส (AWS) สำหรับ Tesla T4 เป็น GPU ที่อยู่ในซีรีส์เอ็นวีเดียเทสลา (NVIDIA Tesla) ซึ่งได้รับการออกแบบมาเพื่อให้เหมาะสมกับการทำงานด้านการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึกที่ต้องการการคำนวณที่มีประสิทธิภาพสูง เมื่อทำการกำหนด Runtime เป็น GPU เรียบร้อยแล้ว จะสามารถใช้สมรรถนะต่างๆ ของ GPU ได้โดยอัตโนมัติ


1.8.2 การเรียกใช้ชุดข้อมูลที่กูเกิลไดรฟ์ (Google Drive)

ในกรณีที่มีชุดข้อมูล (Data Set) ขนาดใหญ่ ตัวอย่างเช่นชุดข้อมูลการทำธุรกรรมทางการเงินของลูกค้าธนาคารย้อนหลัง 10 ปี ชุดข้อมูลภาพผลไม้จำนวน 10,000 ภาพ (ประกอบด้วยผลไม้จำนวน 100 ชนิด และชนิดละ 100 ภาพ) หรือชุดข้อมูลเสียงโอของโรคเกี่ยวกับทางเดินหายใจจำนวน 23,000 คลิป (มีขนาดรวมทั้งสิ้น 40.15 กิกะไบต์) เป็นต้น เมื่อนำไฟล์ชุดข้อมูลเหล่านี้จัดเก็บไว้ที่กูเกิลไดรฟ์และต้องการเรียกใช้ซึ่งสามารถใช้คำสั่ง `drive.mount()` เพื่อเชื่อมต่อกับกูเกิลไดรฟ์ โดยในกูเกิลโคแลบสามารถใช้คำสั่ง `google.colab.drive.mount()` เพื่อเชื่อมต่อระหว่างกูเกิลไดรฟ์กับโคแลบ (Colab)


ตัวอย่างคำสั่ง `drive.mount()`

บรรทัดที่	โปรแกรม
1	<code>from google.colab import drive</code>
2	<code>drive.mount('/content/drive')</code>

เมื่อรันคำสั่ง `drive.mount()` ระบบจะให้ลิงก์ (Link) ไปที่กูเกิลไดรฟ์เพื่อขออนุญาตการเข้าถึงกูเกิลไดรฟ์จากอีเมลให้คลิกที่ปุ่ม Connect to Google Drive เพื่อเชื่อมต่อระหว่างกูเกิลไดรฟ์และโคแลบ ดังแสดงในรูปที่ 1.12



รูปที่ 1.12 การขออนุญาตการเข้าถึงกูเกิลไดรฟ์จากกูเกิลโคแลบ



การเรียนรู้เชิงลึก

(Deep Learning)

โดยใช้ Python เพื่อวิเคราะห์ธุรกิจ

หนังสือ **AI การเรียนรู้เชิงลึก (Deep Learning) โดยใช้ Python เพื่อวิเคราะห์ธุรกิจ** เล่มนี้ ประกอบด้วย 2 ส่วนหลักคือ ภาคทฤษฎี ได้แก่ หลักการเรียนรู้เชิงลึก และกระบวนการและอัลกอริทึมการเรียนรู้เชิงลึก และภาคประยุกต์ ได้แก่ การนำเสนอโจทย์ปัญหาและตัวอย่างการพัฒนาแบบจำลองด้วยภาษาไพธอน การทำงานด้านต่างๆ ด้วยอัลกอริทึมการเรียนรู้เชิงลึก การจำแนกการแสดงผลออกทางอารมณ์บนใบหน้าด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) สำหรับการตรวจจับพฤติกรรมในระบบรักษาความปลอดภัย การพยากรณ์ราคาทองคำด้วยอัลกอริทึมหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) การตรวจจับการฉ้อโกงทางการเงินในระบบธนาคารด้วยอัลกอริทึมโครงข่ายปฏิกิริยาเชิงสร้างสรรค์ (Generative Adversarial Networks : GANs) การเรียนรู้การถ่ายโอน (Transfer Learning) การปรับใช้แบบจำลองการเรียนรู้เชิงลึกด้วย Flask Framework ที่เว็บแอปพลิเคชัน และการแสดงผลข้อมูลของแบบจำลองการเรียนรู้เชิงลึกด้วยเทนเซอร์บอร์ด (TensorBoard) โดยหลักการเรียนรู้เหล่านี้จะช่วยให้ผู้อ่านสามารถประยุกต์ใช้งานได้จริง



เกี่ยวกับผู้เขียน **รศ.ดร. วุฒิชัย ร่มสายหยุด**

อาจารย์ประจำสาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช ประสบการณ์ด้านการสอนวิชาการวิเคราะห์ข้อมูลขนาดใหญ่สำหรับธุรกิจ ความมั่นคงปลอดภัยฐานข้อมูล ข้อมูลขนาดใหญ่และเหมืองข้อมูล ฐานข้อมูลเรียลไทม์ไฟร์เบส การพัฒนา Neo4j สำหรับแอปพลิเคชันต่าง ๆ และยังเป็นผู้เขียนหนังสือทางด้านคอมพิวเตอร์ให้กับบริษัท ซีอีดูเคชั่น จำกัด (มหาชน) และสำนักพิมพ์มหาวิทยาลัยสุโขทัยธรรมาธิราช



พร้อมจำหน่ายในรูปแบบ

- ☒ e-book (PDF) ☐ e-book (EPUB) ☐ audiobooks
☒ ปกอ่อน ☐ LARGE PRINT (ตัวอักษรขนาดใหญ่)



www.se-ed.com



sbc.fans



SE-ED Publisher

printed with
SoyInk

ISBN 978-616-08-5496-7



9 786160 854967
259 บาท

คอมพิวเตอร์-การเขียนโปรแกรม