

การพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 สะสมโดยใช้การเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต


สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2564

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

COVID-19 cumulative case forecasting by Deep Learning



Mr. Tossapon Nuanchuay

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 สะสมโดยใช้การเรียนรู้เชิงลึก
โดย	นายทศพล นวลช่วย
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.สุกรี สินธุภิญโญ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.นันทิ นิภานันท์)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.สุกรี สินธุภิญโญ)	
.....	กรรมการ
(รองศาสตราจารย์ ดร.ณัฐพงศ์ ชินธเนศ)	
.....	กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.เด่นดวง ประดับสุวรรณ)	

บทพล นวลช่วย : การพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 สะสมโดยใช้การ
เรียนรู้เชิงลึก. (COVID-19 cumulative case forecasting by Deep Learning) อ.ที่
ปรึกษาหลัก : ผศ. ดร.สุกรี สิ้นธุภิญโญ

นับตั้งแต่ธันวาคม 2019 โรคติดเชื้อโคโรนาไวรัส 2019 หรือ โควิด-19 เป็นโรคที่เริ่ม
แพร่กระจายจากคนสู่คน การแพร่ระบาดเกิดขึ้นอย่างรวดเร็วและคาดเดาไม่ได้อันเนื่องมาจาก
ปัจจัยส่งเสริมในหลาย ๆ ด้าน ส่วนหนึ่งคือการท่องเที่ยวระหว่างประเทศ หลังจากการค้นพบการ
ติดเชื้อระหว่างคนสู่คนครั้งแรกไม่นาน องค์การอนามัยโลกได้ประกาศในวันที่ 21 มกราคม 2020
ประกาศภาวะฉุกเฉินทั่วโลกต่อการแพร่กระจายที่รวดเร็วของโรคนี้ มีการสร้างโมเดลจำลองการ
แพร่กระจายของโรคติดเชื้อโคโรนาไวรัส 2019 เพื่อใช้ในการพยากรณ์และออกแบบนโยบายเพื่อ
การป้องกันต่อไป โดยเทคนิคที่ใช้ในการสร้างโมเดลมีหลายหลายแบบ ทั้งแบบคลาสสิกและการใช้
เครือข่ายประสาทเทียม เพื่อความแม่นยำที่มากขึ้นงานวิจัยชิ้นนี้ได้สร้างโมเดลที่ใช้ข้อมูลทางสถิติใน
มิติอื่น ๆ นอกเหนือจากข้อมูลทางสถิติด้านจำนวนผู้ติดเชื้อ การทดลองถูกออกแบบมาเพื่อหา
วิธีการสร้างโมเดลที่ดีที่สุดและเปรียบเทียบกับโมเดลที่ใช้ข้อมูลเพียงด้านเดียวทั้งในการพยากรณ์
จำนวนผู้ติดเชื้อสะสมและการพยากรณ์แนวโน้มการติดเชื้อ ผลการทดลองแสดงให้เห็นว่าการใช้
ข้อมูลด้านเดียวสามารถพยากรณ์จำนวนผู้ติดเชื้อสะสมในอนาคตได้แม่นยำที่สุดและการใช้ข้อมูล
ทั้ง 14 ชนิดสามารถพยากรณ์แนวโน้มผู้ติดเชื้อรายวันได้แม่นยำที่สุด

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2564

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270100021 : MAJOR COMPUTER SCIENCE

KEYWORD: Neural Network, Deep learning, LSTM, Multivariable Forecasting,
COVID-19

Tossapon Nuanchuay : COVID-19 cumulative case forecasting by Deep Learning. Advisor: Asst. Prof. Dr. SUKREE SINTHUPINYO

Since December 2019, Coronavirus 2019 (COVID-19) has started spreading human-to-human. The unforeseen and rapid spread of COVID-19 has multiple factors, but a major reason is people's travelling both domestic and international. Shortly after discovered of human-to-human transmission, World Health Organization (WHO) announced a global emergency on January 21, 2020 to this pandemic. There are multiple forecasting systems established to help forecast COVID-19 case trend and deploy any policy to reduce infection rate. Both classical computational and Neural Network have been used to build forecasting systems. In order to increase preciseness of the forecasting, we show a model that is trained with cumulative case data type can achieve highest accuracy when it predicts number of cumulative cases in next 7 and 21 days ahead. Another model is trained with 14 different data type can achieve incredibly highest accuracy when it is used to classify the direction of the trend in next 7 and 21 days.

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Computer Science

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้ได้รับความอนุเคราะห์จากผู้ช่วยศาสตราจารย์ ดร. สุกรี สิริบุญโญ ที่ปรึกษาวิทยานิพนธ์ที่ได้ให้คำแนะนำแนวทางการตั้งโจทย์ปัญหา วิธีการหาคำตอบ วิธีการวิจัย วิธีการตีพิมพ์ผลงานทางวิชาการและการเขียนวิทยานิพนธ์ อีกทั้งยังช่วยตรวจสอบแก้ไขข้อผิดพลาดต่าง ๆ ผู้วิจัยขอขอบคุณเป็นอย่างสูง

ขอขอบคุณ ผู้ช่วยศาสตราจารย์ ดร. นัทธี นิภานันท์ ประธานกรรมการสอบวิทยานิพนธ์ รองศาสตราจารย์ ดร. ณัฐพงศ์ ชินธเนศ และ ผู้ช่วยศาสตราจารย์ ดร. เด่นดวง ประดับสุวรรณ กรรมการสอบวิทยานิพนธ์ที่ได้เสียสละเวลาอันมีค่า ชี้ให้เห็นถึงจุดที่สามารถปรับปรุง แนวทาง และคำแนะนำที่เป็นประโยชน์ในการทำวิทยานิพนธ์

สุดท้ายนี้ขอขอบคุณผู้เกี่ยวข้องทุกท่านที่ไม่ได้กล่าวมาข้างต้นที่คอยให้ความช่วยเหลือทำให้การทำวิทยานิพนธ์นี้สำเร็จลุล่วงไปได้ด้วยดี ผู้วิจัยหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อผู้สนใจไม่มากนัก

ทศพล นวลช่วย



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
บทที่ 1 บทนำ	2
1.1 ที่มาและความสำคัญ.....	2
1.2 วัตถุประสงค์การวิจัย	3
1.3 ขอบเขตของงานวิจัย	4
1.4 ขั้นตอนการดำเนินงาน.....	4
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	5
1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์	5
1.7 ผลงานที่ได้รับการตีพิมพ์จากวิทยานิพนธ์	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	6
2.1 ทฤษฎีที่เกี่ยวข้อง.....	6
2.1.1 ความจำขนาดสั้นระยะยาว (Long Short-Term Memory)	6
2.1.2 เกตรีเคอร์เรนตียูนิต (Gated Recurrent Unit)	8
2.1.3 การพยากรณ์.....	9
2.1.4 แบบจำลองทางระบาดวิทยา	10
2.2 งานวิจัยที่เกี่ยวข้อง	12

2.2.1 Deep Learning for COVID-19 prediction 12

2.2.2 COVID-19 Time Series Forecasting of Daily Cases, Deaths Caused and Recovered Cases using Long Short Term Memory Networks..... 12

2.2.3 Deep learning via LSTM models for COVID-19 infection forecasting in India

14

บทที่ 3 แนวคิดและวิธีการวิจัย 17

3.1 ชุดข้อมูล 19

3.2 การเตรียมข้อมูล 21

3.3 การสร้างโมเดลเครือข่ายหน่วยความจำขนาดสั้นระยะยาวแบบวานิลลา (Vanilla Long Short-Term Memory)..... 22

3.4 การสร้างโมเดลเครือข่ายหน่วยความจำขนาดสั้นแบบวานิลลาเกตรีเคอร์เรนต์ยูนิต (Vanilla Gated Recurrent Unit)..... 23

3.5 การสร้างโมเดลเครือข่ายประสาทเทียมความจำขนาดสั้นระยะยาวหลายชั้น (Stacked Long Short-Term Memory)..... 23

3.6 การทดสอบไขว้ข้าม K กลุ่ม 24

บทที่ 4 การออกแบบและพัฒนาแบบจำลอง 27

4.1 การทดลองเปรียบเทียบสถาปัตยกรรมและจำนวนวันที่เหมาะสม..... 27

4.2 การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมในแต่ละประเทศโดยใช้ข้อมูลเพิ่มเติม 29

4.3 การทดลองพยากรณ์แนวโน้มผู้ติดเชื้อรายใหม่ 32

4.4 การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยโมเดลที่เรียนรู้จากข้อมูลแนวโน้มเดียว..... 36

บทที่ 5 สรุปผลการวิจัย 38

5.1 สรุปผลการวิจัย 38

5.2 งานวิจัยในอนาคต..... 39

บรรณานุกรม..... 41

ประวัติผู้เขียน 45



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

หน้า

ตาราง 1 ข้อมูล เทคนิค และวิธีการวัดผลของงานวิจัยที่เกี่ยวข้อง.....	17
ตาราง 2 สรุปข้อมูลที่ใช้ในงานวิจัย	20
ตาราง 3 สภาพแวดล้อมที่ใช้ในการทดลองหาขนาดของข้อมูลและสถาปัตยกรรมที่เหมาะสม	28
ตาราง 4 ตารางค่าเฉลี่ยผิดพลาดร้อยละสัมบูรณ์จากการทำนายจำนวนผู้ติดเชื้อในอนาคต 7 วัน....	29
ตาราง 5 ตารางค่าเฉลี่ยผิดพลาดร้อยละสัมบูรณ์จากการทำนายจำนวนผู้ติดเชื้อในอนาคต 21 วัน..	29
ตาราง 6 ความสัมพันธ์ระหว่างจำนวนผู้ป่วยสะสมและข้อมูลอื่น	30
ตาราง 7 ข้อมูลและสภาพแวดล้อมในการทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมในแต่ละประเทศ..	30
ตาราง 8 ค่าความผิดพลาดเฉลี่ยร้อยละสัมบูรณ์ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยข้อมูล แนวโน้มจำนวนผู้ติดเชื้อรายวันชนิดเดียวกันในอีก 7 วันข้างหน้า	36
ตาราง 9 ค่าความผิดพลาดเฉลี่ยร้อยละสัมบูรณ์ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยข้อมูล แนวโน้มจำนวนผู้ติดเชื้อรายวันชนิดเดียวกันในอีก 21 วันข้างหน้า	36

สารบัญรูปภาพ

หน้า

รูปที่ 1 โครงสร้างเซลล์ความจำขนาดสั้นระยะยาว	7
รูปที่ 2 โครงสร้างเซลล์เกตรีเคอร์เรนต์ยูนิต	9
รูปที่ 3 โครงสร้างสถาปัตยกรรมที่นำเสนอโดย S. Bodapati และคณะ	13
รูปที่ 4 การทำนายผู้ติดเชื้อรายวันจากโมเดลของ S. Bodapati และคณะ	14
รูปที่ 5 สถาปัตยกรรมที่มีพื้นฐานจากความจำขนาดสั้นระยะยาวที่ใช้ในงานของ R. Chandra	15
รูปที่ 6 สถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัส	15
รูปที่ 7 การสร้างข้อมูลนำเข้าโดยมี $M = 4$ และ $N = 5$	22
รูปที่ 8 โครงสร้างโมเดล Vanilla long short-term memory	22
รูปที่ 9 โครงสร้างโมเดล Vanilla gated recurrent unit	23
รูปที่ 10 โครงสร้างสถาปัตยกรรมความจำขนาดสั้นระยะยาว 2 ชั้น	24
รูปที่ 11 การแบ่งข้อมูลของการทดสอบไขว้ข้าม K กลุ่ม	25
รูปที่ 12 รูปแบบการแบ่งตามเวลาเกิด	25
รูปที่ 13 รูปแบบการแบ่งหารเอาเศษ	26
รูปที่ 14 แผนภูมิเปรียบเทียบค่าความผิดพลาดร้อยละสมบูรณ์ของข้อมูลเพิ่มเติมแต่ละชนิดในการทำนายจำนวนผู้ติดเชื้อสะสมใน 7 วันข้างหน้า	31
รูปที่ 15 แผนภูมิเปรียบเทียบค่าความผิดพลาดร้อยละสมบูรณ์ของข้อมูลเพิ่มเติมแต่ละชนิดในการทำนายจำนวนผู้ติดเชื้อสะสมใน 21 วันข้างหน้า	32
รูปที่ 16 เส้นแบ่งระหว่างลักษณะแนวโน้มและตัวอย่างข้อมูล	33
รูปที่ 17 ตัวอย่างสถาปัตยกรรมที่ใช้ในการจำแนกแนวโน้มการเพิ่มขึ้นของผู้ติดเชื้อ	34
รูปที่ 18 แผนภูมิความแม่นยำการทำนายแนวโน้มในอนาคต	35

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

โรคติดเชื้อไวรัสโคโรนาสายพันธุ์ใหม่ 2019 หรือ โรคติดเชื้อไวรัสโคโรนา 2019 เป็นโรคติดต่อที่มีการแพร่ระบาดอย่างต่อเนื่องเป็นวงกว้างในหลายประเทศทั่วโลก การแพร่เชื้อไวรัสโคโรนา 2019 สามารถแพร่เชื้อจากคนสู่คนได้โดยมีอากาศเป็นตัวกลางที่นำสารคัดหลั่งที่เกิดจากการไอหรือจามของผู้ติดเชื้อกระจายไปยังบุคคลอื่นหรือไปติดกับพื้นผิวที่บุคคลอื่นสามารถสัมผัสและนำไวรัสเข้าสู่ร่างกายได้โดยมีระยะเวลาห่างจากการติดเชื้อและแสดงอาการตั้งแต่ 1-14 วัน อาการที่พบมากที่สุดของโรคติดเชื้อไวรัสโคโรนา 2019 ได้แก่ มีไข้สูง ไอ อ่อนเพลีย หายใจติดขัด ปวดข้อหรือกล้ามเนื้อ และ เจ็บคอ เป็นต้น กลุ่มเด็กและวัยหนุ่มสาวจะมีความเสี่ยงที่มีอาการรุนแรงต่ำกว่ากลุ่มที่มีอายุมากและมีโรคประจำตัว เช่น โรคความดันโลหิตสูง โรคเบาหวาน โรคหลอดเลือดหัวใจ และเห็นได้ว่าโรคติดเชื้อไวรัสโคโรนา 2019 สามารถระบาดได้ง่ายในชุมชนแออัด การชุมนุมขนาดใหญ่หรือแม้แต่การสัมผัสเชื้อโรคมาจากต่างประเทศจึงทำให้เกิดมาตรการทางสาธารณสุข ได้แก่ การกักตัวผู้ที่มีความเสี่ยงหรือมีอาการ การเว้นระยะห่าง การติดตามสัมผัสโรค วิกฤตโลกในครั้งนี้ส่งผลกระทบทั้งทางเศรษฐกิจและสังคมและไม่สามารถทำนายได้แม่นยำว่าการระบาดครั้งนี้จะสิ้นสุดลงเมื่อใด

เอส-ไอ-อาร์ (Susceptible-Infectious-Recovered) เป็นเทคนิคที่ใช้ในการทำนายแนวโน้มการระบาดของโรค เป็นโมเดลทางคณิตศาสตร์ที่ได้รับความนิยมและคลาสสิกที่จะจำลองให้เห็นแนวโน้มจำนวนผู้ติดเชื้อและผู้ได้รับการรักษาเมื่อมีจำนวนประชากรที่ระบุได้ [1] ด้วยโมเดลเอส-ไอ-อาร์เป็นที่ยอดนิยมและมีพื้นฐานมาจากแบบจำลองสุ่ม (Stochastic model) จึงสามารถพลิกแพลงเพื่อให้เข้ากับสถานการณ์การแพร่เชื้อ เช่น การพลิกแพลงไปสู่โมเดลเอส-อี-ไอ-อาร์ (Susceptible-Exposed-Infectious-Recovered) และ เอส-อี-ไอ-คิว-อาร์-ดี-พี (Susceptible-Exposed-Infectious-Quarantined-Recovered-Death-Protected) ซึ่งมีสถานะเพิ่มเติมที่ทำให้โมเดลมีความยืดหยุ่นมากกว่า เอส-ไอ-อาร์ และมีความเหมาะสมกับการพยากรณ์การระบาดในปัจจุบัน ตัวอย่างสถานะเพิ่มเติม เช่น สถานะกักตัว และ สถานะได้รับการปกป้อง เป็นต้น [2] [3] [4] นอกจากคลาสสิกโมเดลที่กล่าวมา ในปัจจุบันเทคโนโลยีการคำนวณมีความก้าวหน้าไปมาก การคำนวณเพื่อแก้ปัญหาที่มีความรวดเร็วขึ้นในขณะที่ใช้ทรัพยากรน้อยลงเป็นเหตุให้มีการใช้เทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมากยิ่งขึ้น มีการนำการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมาใช้ในการพยากรณ์การระบาดของโรคต่าง ๆ มากมาย การใช้งานการเรียนรู้ของเครื่องแบบมีผู้สอนหลากหลายแบบถูกนำมาใช้ใน

การพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 เช่น การถดถอยเส้นตรง ลาซโซ่ ซัพพอร์ตเวกเตอร์แมชชีน การเรียนรู้ด้วยต้นไม้ตัดสินใจ การทำให้เรียบด้วยฟังก์ชันเอกซ์โพเนนเชียล (Exponential Smoothing) และป่าแบบสุ่ม [5] [6] [7] เทคนิคเหล่านี้สามารถใช้ในการพยากรณ์ได้ดีในระดับใช้งาน ได้จริงในช่วงต้น ๆ ของการแพร่ระบาด การระบาดของโรคติดเชื้อไวรัสโคโรนา 2019 มีการแพร่ระบาดหลากหลายรูปแบบ หลายรอบ และการบันทึกจำนวนผู้ติดเชื้อ ผู้เสียชีวิตและผู้รักษาหายอาจมีความคลาดเคลื่อนในแต่ละประเทศทำให้ข้อมูลมีความผันผวนจึงเป็นข้อจำกัดของการใช้การเรียนรู้ของเครื่องแบบมีผู้สอนโดยเฉพาะอย่างยิ่งการใช้สมการถดถอยเส้นตรงที่ไม่สามารถรองรับความผันผวนของข้อมูลได้ นอกจากการใช้งานการเรียนรู้ของเครื่องแล้ว การใช้งานการเรียนรู้เชิงลึกถูกนำมาใช้งานในการพยากรณ์การระบาดของโรคในหลาย ๆ โรค เช่น โรคไข้เลือดออกเป็นต้น [8] [9] ซึ่งสถาปัตยกรรมแบบวนกลับเหมาะสมในการใช้ในการพยากรณ์โรคเนื่องจากรับข้อมูลและพิจารณาข้อมูลของที่เกิดขึ้นก่อนหน้าทำให้สามารถพยากรณ์ได้อย่างแม่นยำ

ในปัจจุบันการใช้งานการเรียนรู้เชิงลึกมีความแพร่หลายและหลากหลายมากในการพยากรณ์การระบาดของโรคติดเชื้อไวรัสโคโรนา 2019 มีการนำเสนอการใช้งานการเรียนรู้ของเครื่องเชิงลึกในสถาปัตยกรรมแบบต่าง ๆ เช่น เครือข่ายประสาทเทียมวนกลับ ความทรงจำขนาดสั้นระยะยาว เกรตริเคอร์เรนต์ยูนิต เครือข่ายประสาทเทียมคอนโวลูชันและประสาทเทียมหลายชั้น ข้อมูลที่ใช้มีความหลากหลายทั้งขนาดและรูปแบบ [10] [11] [12] ทั้งนี้ยังมีชุดข้อมูลที่น่าสนใจอีกมากมายที่ได้รับการเผยแพร่ไม่นานมานี้ เช่น จำนวนการฉีดวัคซีนเป็นต้น ทั้งนี้การสังเคราะห์ข้อมูลให้ก็เป็นที่น่าสนใจ เช่นจำนวนการติดเชื้อในแต่ละภูมิภาค ผู้วิจัยจึงได้นำมาทดลองเพื่อหาความสัมพันธ์ระหว่างข้อมูลเพื่อให้ได้โมเดลการพยากรณ์ที่ดีที่สุด

1.2 วัตถุประสงค์การวิจัย

1. เพื่อศึกษาวิธีการสร้างแบบจำลองที่สามารถพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนาสะสมทั้งการพยากรณ์ระยะใกล้และระยะไกลโดยใช้เครือข่ายประสาทเทียมและปัจจัยที่ส่งผลกระทบต่อประสิทธิภาพของการพยากรณ์ ทั้งทางด้านตัวแปรของเครือข่ายประสาทเทียมและชนิดของข้อมูลที่อาจมีผลต่อประสิทธิภาพของการพยากรณ์
2. เพื่อศึกษาการสร้างแบบจำลองที่สามารถบอกแนวโน้ม ทิศทางของจำนวนผู้ติดเชื้อรายใหม่ประจำวันโดยใช้การเรียนรู้เชิงลึกโดยใช้ข้อมูลชนิดเดียวกันกับที่ใช้ในการพยากรณ์จำนวนผู้ติดเชื้อสะสม

1.3 ขอบเขตของงานวิจัย

1. ข้อมูลการระบาดของโรคติดเชื้อไวรัสโคโรนา 2019 ตั้งแต่วันที่ 29 ธันวาคม 2019 ถึงวันที่ 11 กรกฎาคม 2021 ประกอบด้วย จำนวนผู้ติดเชื้อสะสม จำนวนผู้ติดเชื้อรายใหม่ จำนวนผู้เสียชีวิตสะสม จำนวนผู้เสียชีวิตรายใหม่ จำนวนการฉีดวัคซีนทั้งหมด ในแต่ละประเทศในแต่ละวัน [13]
2. ข้อมูลภูมิประเทศจาก Geo Data Source [14]
3. ข้อมูลการเคลื่อนที่ของประชากรในแต่ละประเทศจาก Google Mobility Report
4. การพยากรณ์จำนวนผู้ติดเชื้อสะสมในอีก 7 และ 21 วันข้างหน้า
5. วัดผลด้วยค่าเฉลี่ยร้อยละความผิดพลาดสัมบูรณ์จากไลบรารีเคราส
6. การทำให้เป็นมาตรฐานด้วยฟังก์ชันอัตราส่วนการเบี่ยงเบนของคะแนนจากค่าเฉลี่ยจากไลบรารีเอสเคเลิร์น (SciKit-Learn)
7. สถาปัตยกรรมการเรียนรู้เชิงลึก คือ ความจำขนาดสั้นระยะยาวและเกตริคอร์เรนต์ยูนิต

1.4 ขั้นตอนการดำเนินงาน

1. ศึกษางานวิจัยเกี่ยวกับสถาปัตยกรรมและเทคนิคที่ใช้ในการพยากรณ์จำนวนผู้ติดเชื้อโรคระบาด
2. วิเคราะห์หาข้อดีข้อเสียของแต่ละสถาปัตยกรรมและเทคนิค
3. กำหนดขอบเขตและจัดประสงค้งานวิจัย
4. กำหนดวิธีการได้มาของข้อมูล
5. ทำความสะอาดข้อมูลด้วยเทคนิคที่ศึกษามา
6. การทดลองเลือกชนิดของสถาปัตยกรรมที่เหมาะสมในการพยากรณ์จำนวนผู้ติดเชื้อสะสม
7. การทดลองหาชนิดข้อมูลที่เหมาะสมในการพยากรณ์จำนวนผู้ติดเชื้อสะสมโดยมีพื้นฐานจาก
8. สถาปัตยกรรมจากการทดลองที่ 1
9. การทดลองพยากรณ์แนวโน้มจำนวนผู้ติดเชื้อรายวันในอนาคต
10. การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยโมเดลที่เรียนรู้ด้วยแนวโน้มเดียวด้วยข้อมูลชนิดต่าง ๆ
11. ตีพิมพ์ผลงานและเรียบเรียงวิทยานิพนธ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถสร้างแบบจำลองการเพิ่มขึ้นของจำนวนผู้ติดเชื้อสะสมด้วยการเรียนรู้เชิงลึก
2. สามารถสร้างแบบจำลองแสดงแนวโน้มจำนวนผู้ติดเชื้อรายใหม่ด้วยการเรียนรู้เชิงลึก
3. เห็นถึงตัวแปรปัจจัยที่ส่งผลต่อการเพิ่มขึ้นและลดลงของจำนวนผู้ติดเชื้อ

1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์

เนื้อหาของวิทยานิพนธ์นี้แบ่งออกเป็น 5 บทได้แก่ บทที่ 1 บทนำ ประกอบด้วย ที่มาและความสำคัญ วัตถุประสงค์การวิจัย ของเขตการวิจัย ขั้นตอนการดำเนินงาน ประโยชน์ที่คาดว่าจะได้รับ และ ผลงานที่ได้รับการตีพิมพ์จากวิทยานิพนธ์ บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง บทที่ 3 แนวคิดและวิธีวิจัย บทที่ 4 การทดลองและผลการทดลอง และ บทที่ 5 สรุปผลการวิจัย

1.7 ผลงานที่ได้รับการตีพิมพ์จากวิทยานิพนธ์

ส่วนหนึ่งของวิทยานิพนธ์ฉบับนี้ได้รับการตีพิมพ์ผลงานทางวิชาการจำนวน 1 บทความ:

Nuanchuay, T. & Sinthupinyo S. Additional Time Series Features for Preciseness Improvement of LSTM-based COVID-19 Spread Forecasting Model. In 4th International Conference of Machine Learning and Machine Intelligence (MLMI2021). Hangzhou, China.

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ความจำขนาดสั้นระยะยาว (Long Short-Term Memory)

ความจำขนาดสั้นระยะยาว (Long Short-Term Memory หรือ LSTM) ถูกคิดค้นและนำเสนอโดย Sepp Hochrieter และ Jurgen Schmidhuber [15] เป็นหนึ่งในสถาปัตยกรรมเครือข่ายประสาทเทียมวงกลับ (Recurrent neural network) ที่ได้รับความนิยม หนึ่งในเหตุผลที่ทำให้สถาปัตยกรรมนี้ได้รับความนิยมคือการแก้ปัญหาการหายไปของค่าความผิดพลาด (Vanishing Gradient) และการระเบิดของค่าความผิดพลาด (Exploding Gradient) ซึ่งเป็นปัญหาที่เจอในสถาปัตยกรรมวงกลับแบบทั่วไป (Vanilla Recurrent Neural Network) องค์ประกอบภายในประกอบด้วยเกต 3 ชนิด คือ เกตลืมข้อมูล เกตข้อมูลขาเข้า และ เกตข้อมูลขาออก และ เซลล์ผู้ทำซิง และข้อมูลขาออก ทั้งหมดนี้ประกอบกันเป็นความจำขนาดสั้นระยะยาว 1 เซลล์ด้วยองค์ประกอบเหล่านี้ทำให้มีการส่งผ่านและรับข้อมูลจากเซลล์ก่อนหน้าได้ทำให้เกิดการเรียนรู้และส่งค่าความผิดพลาดไปยังเซลล์ก่อนหน้า (Backpropagation through time) ได้ โดยเกิดการลืมข้อมูล f_t ประกอบด้วยเมทริกซ์ข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_f รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_f และนำเข้าไปในฟังก์ชันซิกมอยด์

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f)$$

เกตข้อมูลขาเข้า i_t ประกอบด้วยเมทริกซ์ข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_i รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_i และนำเข้าไปในฟังก์ชันซิกมอยด์

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i)$$

เกตข้อมูลขาออก o_t ประกอบด้วยเมทริกซ์ข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_o รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_o และนำเข้าไปในฟังก์ชันซิกมอยด์

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o)$$


เซลล์ผู้ทำซิง \tilde{c}_t ประกอบด้วยเมทริกซ์ข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_c รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_c และนำเข้าไปในฟังก์ชันซิกมอยด์

$$\tilde{c}_t = \sigma_c(W_c x_t + U_c h_{t-1} + b_c)$$

ภายในความจำขนาดสั้นระยะยาวเก็บข้อมูลของเซลล์ไว้ที่ c_t ซึ่งประกอบขึ้นจากเกตการลืม f_t ข้อมูลคูณด้วยเซลล์ข้อมูลของเซลล์ก่อนหน้า c_{t-1} บวกกับ เกตข้อมูลขาเข้า i_t คูณกับเซลล์ข้อมูลทำซิง \tilde{c}_t สมการนี้แสดงให้เห็นการนำข้อมูลจากเซลล์ก่อนหน้าที่ถูกควบคุมด้วยเกตการลืมและการนำข้อมูลเซลล์ปัจจุบันที่ถูกควบคุมด้วยเกตข้อมูลขาเข้ามาใช้ในการพิจารณาข้อมูลขาออก

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t$$

ท้ายที่สุดข้อมูลขาออก h_t มีค่าเท่ากับเกตข้อมูลขาออก o_t คูณกับเซลล์ข้อมูลที่ถูกระงับด้วยฟังก์ชันซิกมอยด์ $\sigma_t(c_t)$ รูปที่ 1 แสดงโครงสร้างภายในเซลล์ความจำขนาดสั้นระยะยาว



รูปที่ 1 โครงสร้างเซลล์ความจำขนาดสั้นระยะยาว

เวลาต่อมามีการปรับปรุงเซลล์ความจำขนาดสั้นระยะยาวโดยให้ใช้ค่าข้อมูลเซลล์ของเซลล์ก่อนหน้าแทนผลลัพธ์ของเซลล์ก่อนหน้า [16] [17] ซึ่งจะทำให้สมการของเกตการลืมข้อมูล f_t เกตข้อมูลขาเข้า i_t และเกตข้อมูลขาออก o_t เปลี่ยนจากการใช้ผลลัพธ์จากเซลล์ก่อนหน้าเป็นข้อมูลเซลล์ของเซลล์ก่อนหน้า

$$f_t = \sigma_g(W_f x_t + U_f c_{t-1} + b_f)$$

$$i_t = \sigma_g(W_i x_t + U_i c_{t-1} + b_i)$$

$$o_t = \sigma_g(W_o x_t + U_o c_{t-1} + b_o)$$

และจะยกเลิกการใช้เซลล์ผู้ทำซิงโดยค่าของข้อมูลเซลล์ c_t ประกอบขึ้นจาก

$$c_t = f_g \circ c_{t-1} + i_t \circ (W_c x_t + b_c)$$

ในปัจจุบันมีการงานสถาปัตยกรรมชนิดนี้อย่างแพร่หลายทั้งเพื่อการแก้ปัญหาการจัดหมวดหมู่ (Classification) และปัญหาในเชิงการพยากรณ์ สถาปัตยกรรมนี้ได้รับความนิยมอย่างมากในการแก้ปัญหาด้านการประมวลผลภาษาธรรมชาติ [18] การแก้ปัญหาการรับรู้ด้วยเสียง (Speech Recognition) [19] และการพยากรณ์ทางด้านตัวเลข [20]

2.1.2 เกตรีเคอร์เรนตียูนิต (Gated Recurrent Unit)

ในปี 2014 Kyunghyun Cho และคณะได้นำเสนอสถาปัตยกรรมวงกลับเกตรีเคอร์เรนตียูนิต [21] ที่มีการใช้เกตการลิมข้อมูลเหมือนกับสถาปัตยกรรมความจำขนาดสั้นระยะยาวแต่ลดจำนวนตัวแปรและตัวเซลล์ของเกตรีเคอร์เรนตียูนิตรับเฉพาะผลลัพธ์ของเซลล์ก่อนหน้าไม่เหมือนกับสถาปัตยกรรมความจำขนาดสั้นระยะยาวที่ส่งผ่านทั้งผลลัพธ์และเซลล์ข้อมูล ภายในเซลล์ประกอบด้วย เวกเตอร์อัปเดต z_t เวกเตอร์รีเซ็ต r_t และ เวกเตอร์ผลลัพธ์ทำซิง \tilde{h}_t

เวกเตอร์อัปเดต z_t ประกอบด้วยข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_z รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_z ทั้งหมดถูกนำไปในฟังก์ชันซิกมอยด์

$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z)$$

เวกเตอร์รีเซ็ต r_t ประกอบด้วยข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_r รวมกับผลลัพธ์จากเซลล์ก่อนหน้า h_{t-1} ที่ถูกปรับค่าด้วย U_r ทั้งหมดถูกนำไปในฟังก์ชันซิกมอยด์


$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r)$$

เวกเตอร์ผลลัพธ์ทำซิง \tilde{h}_t เป็นดั่งผลลัพธ์ของเซลล์ที่ยังไม่มีการผสมเข้ากับผลลัพธ์จากเซลล์ก่อนหน้า ประกอบขึ้นจาก ข้อมูลขาเข้า x_t ที่ถูกปรับค่าด้วย W_h รวมกับผลลัพธ์จากเซลล์ก่อนหน้าที่ถูกปรับค่าด้วยเวกเตอร์รีเซ็ต r_t และ U_h ทั้งหมดถูกนำไปในฟังก์ชันไฮเพอร์โบลิก แทนเจน (Hyperbolic Tangent)

$$\tilde{h}_t = \phi_h(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h)$$

และสุดท้ายผลลัพธ์ของเซลล์ h_t ประกอบจากการผสมกันของเซลล์ผลลัพธ์ทำซิงและผลลัพธ์จากเซลล์ก่อนหน้าโดยถูกควบคุมโดยเวกเตอร์อัปเดต z_t รูปที่ 2 แสดงโครงสร้าง

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$



รูปที่ 2 โครงสร้างเซลล์เกตรีเคอร์เรนต์ยูนิต

2.1.3 การพยากรณ์

การพยากรณ์คือกระบวนการทำนายโดยใช้ข้อมูลซึ่งอาจเป็นข้อมูลในอดีตถึงปัจจุบันเพื่อการวิเคราะห์แนวโน้มที่อาจจะเกิดขึ้นในอนาคต ตัวอย่างเช่นการประมาณการตัวแปรหนึ่งที่จะเกิดขึ้นในช่วงเวลาหนึ่งในอนาคต การพยากรณ์มีการใช้วิธีการทางสถิติหลากหลายวิธี เช่น การใช้อนุกรมเวลา การศึกษาข้อมูลตามขวาง (Cross-sectional data) การศึกษาตามยาว (Longitudinal study) เป็นต้น การพยากรณ์อาศัยข้อมูลที่เป็นปัจจุบันเพื่อให้การคาดการณ์มีความแม่นยำมากที่สุด ในบางกรณีข้อมูลที่ใช้ในการพยากรณ์จะเป็นตัวแปรผลลัพธ์การพยากรณ์เอง เช่น การใช้ข้อมูลสภาพอากาศของเมื่อวานในการพยากรณ์สภาพอากาศของวันนี้ ความเสี่ยงและความไม่แน่นอนเป็นสิ่งที่เกิดขึ้นเป็นประจำในการพยากรณ์ จึงต้องมีการบ่งชี้ความไม่แน่นอนของการพยากรณ์

การพยากรณ์สามารถแบ่งออกเป็น 2 รูปแบบตามรูปแบบของผลลัพธ์ คือ การพยากรณ์เชิงคุณภาพและการพยากรณ์เชิงปริมาณ เทคนิคการพยากรณ์เชิงคุณภาพเป็นแบบอัตนัย เหมาะสำหรับการพยากรณ์เมื่อไม่มีข้อมูลในอดีต มักใช้กับการตัดสินใจระยะกลางหรือระยะยาว ตัวอย่างของวิธีการพยากรณ์เชิงคุณภาพได้แก่ ความคิดเห็นและการตัดสินใจของลูกค้า วิธีการเดลฟี (Delphi method) การวิจัยตลาดและการเปรียบเทียบวงจรชีวิตในอดีต เป็นต้น การพยากรณ์เชิงปริมาณใช้เพื่อคาดการณ์ข้อมูลในอนาคตโดยใช้ข้อมูลในอดีต นิยมใช้เมื่อมีข้อมูลในอดีตและมีรูปแบบบางอย่างในข้อมูลนั้นที่คาดว่าจะเกิดขึ้นในอนาคต วิธีการเหล่านี้มักใช้กับการตัดสินใจระยะสั้นหรือระยะกลาง ตัวอย่างของวิธีการพยากรณ์เชิงปริมาณได้แก่ การพยากรณ์อุปสงค์ ค่าเฉลี่ยเคลื่อนที่แบบธรรมดาและแบบใช้น้ำหนัก การปรับแบบเลขชี้กำลังอย่างง่าย การคาดการณ์ตามแบบจำลองกระบวนการปัวซองและดัชนีตามฤดูกาลแบบทวีคูณ เป็นต้น ตัวอย่างวิธีที่ใช้ในการพยากรณ์ เช่น

- ค่าเฉลี่ย เป็นวิธีการพยากรณ์ในอนาคตโดยใช้ค่าเฉลี่ยของข้อมูลในอดีต วิธีนี้ใช้ได้กับข้อมูลทุกประเภทที่มีข้อมูลในอดีต
- การพยากรณ์อย่างง่าย (naïve forecast) เป็นรูปแบบการพยากรณ์ที่มีประสิทธิภาพและสามารถเปรียบเทียบกับแบบจำลองที่ซับซ้อนกว่าได้ วิธีการพยากรณ์นี้เหมาะสำหรับข้อมูลที่เป็นอนุกรมเวลาเท่านั้น หากในข้อมูลอนุกรมเวลาผันผวนตามฤดูกาล การพยากรณ์แบบง่ายตามฤดูกาลอาจเหมาะสมกว่าโดยที่การคาดการณ์จะเท่ากับมูลค่าจากฤดูกาลที่แล้ว
- การพยากรณ์แบบง่ายตามฤดูกาล (Seasonal naïve forecast) วิธีการพยากรณ์อย่างง่ายตามฤดูกาลอธิบายถึงการเปลี่ยนแปลงตามฤดูกาล ซึ่งจะคาดการณ์ตัวแปรให้มีความเท่ากับค่าที่สังเกตได้ในฤดูกาลเดียวกัน ตัวอย่างเช่น ค่าที่พยากรณ์ได้ในเดือนเมษายนปัจจุบันจะมีค่าเท่ากับค่าจริงที่ได้ในเดือนเมษายนที่แล้ว
- วิธีการเมื่อข้อมูลมีลักษณะเป็นอนุกรมเวลา ใช้ข้อมูลในอดีตเป็นพื้นฐานในการประมาณผลลัพธ์ในอนาคต ตัวอย่างวิธีการ เช่น ค่าเฉลี่ยเคลื่อนที่ ค่าเฉลี่ยเคลื่อนที่แบบมีน้ำหนัก การทำให้เรียบลงด้วยฟังก์ชันเลขชี้กำลัง (Exponential Smoothing) ค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ การพยากรณ์เชิงเส้น เครื่องข่ายประสาทเทียมแบบวนกลับ เป็นต้น
- วิธีการเชิงสัมพันธ์ เป็นวิธีการพยากรณ์ที่พยายามใช้ปัจจัยพื้นฐานที่อาจส่งผลต่อตัวแปรที่กำลังถูกพยากรณ์ ตัวอย่างเช่น การรวบรวมข้อมูลเกี่ยวกับรูปแบบสภาพอากาศอาจช่วยปรับปรุงความสามารถของโมเดลในการทำนายยอดขายร่ม หรือ วิธีการที่ไม่เป็นทางการอีกหลากหลายวิธีที่ใช้ในการพยากรณ์ซึ่งไม่สามารถอาศัยผลลัพธ์ของอัลกอริทึมทางคณิตศาสตร์ แต่ใช้วิจารณญาณของผู้พยากรณ์แทน บางข้อพิจารณาถึงความสัมพันธ์ในอดีตระหว่างตัวแปรต่าง ๆ เช่น หากตัวแปรตัวหนึ่งมีความสัมพันธ์แบบเส้นตรงกับตัวแปรอีกตัวหนึ่งเป็นระยะเวลานาน อาจสามารถคาดการณ์ความสัมพันธ์ดังกล่าวในอนาคตโดยไม่ต้องเข้าใจเหตุผลของความสัมพันธ์
- วิธีการทางปัญญาประดิษฐ์ เช่น เครื่องข่ายประสาทเทียม วิธีการจัดการข้อมูลแบบกลุ่ม (GMDH) หรือ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) เป็นต้น

2.1.4 แบบจำลองทางระบาดวิทยา

แบบจำลองทางระบาดวิทยาเป็นแบบจำลองสถานะและเป็นเทคนิคการสร้างแบบจำลองทั่วไป มักใช้กับแบบจำลองทางคณิตศาสตร์สำหรับการแพร่ระบาดของโรคติดต่อ แต่ละสถานะแทนประชากรที่มีคุณลักษณะที่แตกต่างกันเช่น S แทน ประชากรที่อ่อนแอและรับเชื้อได้ I แทน

ประชากรที่ติดเชื้อ และ R แทนประชากรที่หายป่วย ประชากรอาจย้ายจากสถานะเดิมไปยังสถานะหนึ่งได้ และมีเส้นแสดงทิศทางการย้ายสถานะของประชากร เช่น ประชากรย้ายจากสถานะอ่อนแอและรับเชื้อได้ไปสู่สถานะติดเชื้อและย้ายสู่สถานะหายป่วย เป็นต้น แบบจำลองมักใช้สมการเชิงอนุพันธ์ธรรมดาหรือสามารถใช้วิธีการแบบสุ่ม (Stochastic) ซึ่งมีความสมจริงมากกว่าและวิเคราะห์ได้ซับซ้อนมากกว่า โมเดลพยายามทำนายสิ่งต่าง ๆ เช่น การแพร่กระจายของโรค จำนวนผู้ติดเชื้อทั้งหมด หรือระยะเวลาของการแพร่ระบาด เป็นต้น และใช้เพื่อประมาณค่าพารามิเตอร์ทางระบาดวิทยา เช่น จำนวนการเกิดขึ้นซ้ำ (การขยายพันธุ์ของเชื้อ) นอกเหนือจากนี้โมเดลยังแสดงให้เห็นถึงการแทรกแซงด้านสาธารณสุขที่แตกต่างกัน อาจส่งผลต่อผลลัพธ์ของการแพร่ระบาด เช่น การหาเทคนิคในการฉีดวัคซีนที่มีประสิทธิภาพเมื่อมีจำนวนวัคซีนที่จำกัดในประชากรที่กำหนด

โมเดลแบบเอสไออาร์เป็นหนึ่งในแบบจำลองสถานะที่ง่ายที่สุด แบบจำลองส่วนใหญ่ใช้โมเดลนี้เป็นต้นแบบพื้นฐาน ประกอบด้วย 3 สถานะ

- สถานะ S (Susceptible) แสดงจำนวนประชากรที่อ่อนแอ เมื่อประชากรที่อ่อนแอได้รับเชื้อจนติดเชื้อจะย้ายไปสู่สถานะติดเชื้อ
- สถานะ I (Infectious) แสดงจำนวนผู้ติดเชื้อ ประชากรเหล่านี้เป็นประชากรที่ติดเชื้อและสามารถแพร่เชื้อไปยังบุคคลที่อ่อนแอได้
- สถานะ R (Removed) สำหรับประชากรที่เสียชีวิต หรือ ได้รับภูมิคุ้มกัน ประชากรเหล่านี้คือประชากรที่ติดเชื้อและหายจากโรคหรือเสียชีวิต
- โมเดลนี้พยากรณ์ได้อย่างสมเหตุสมผลสำหรับโรคระบาดที่ถ่ายทอดจากคนสู่คนและเมื่อหายจากการติดเชื้อจะได้รับภูมิคุ้มกัน เช่น โรคหัด โรคคางทูม และหัดเยอรมัน เป็นต้น
- นอกเหนือจากนี้ยังมีโมเดลอื่น ๆ ที่ใช้โมเดล SIR เป็นพื้นฐาน
- SIS (Susceptible-Infectious-Susceptible) ในการติดเชื้อบางโรคเช่นโรคหวัดทั่วไปภูมิคุ้มกันไม่สามารถคงอยู่ได้นาน เปิดโอกาสให้ประชากรสามารถติดเชื้อซ้ำได้
- SIRD (Susceptible-Infectious-Recovered-Deceased) แตกต่างจาก SIR ทั่วไปโดยแบ่งแยกระหว่างประชากรที่รักษาหายและเสียชีวิต
- SIRD (Susceptible-Infectious-Recovered-Vaccinated) เพิ่มเติมจาก SIR ทั่วไปโดยการเพิ่มสถานะการได้รับวัคซีน

- MSIR (Maternally Derived Immunity-Susceptible-Infectious-Recovered) ในหลาย ๆ โรค รวมถึงโรคหัด ทารกไม่ได้เกิดมาอยู่ในกลุ่มประชากรที่อ่อนแอ (Susceptible) แต่จะมีภูมิคุ้มกันในระยะแรกไม่กี่เดือน โมเดลนี้เพิ่มสถานะ M ที่จุดเริ่มต้นของโมเดล
- SIRC (Susceptible-Infectious-Recovery-Carrier) สำหรับประชากรบางกลุ่ม ในโรคบางโรคอย่างเช่น วัณโรค ผู้ป่วยไม่สามารถกลับมาหายได้เป็นปกติและยังคงได้รับเชื้ออยู่และสามารถกลับมาป่วยใหม่ได้อีกรอบ ตัวอย่างโรคที่มีการเปลี่ยนแปลงในลักษณะนี้เช่นโรคไทฟอยด์
- SEIR (Susceptible-Exposed-Infectious-Recovered) ในโรคระบาดที่สำคัญบางโรค จะมีช่วงเวลาที่ผู้ติดเชื้อได้รับเชื้อแต่ยังไม่สามารถแพร่เชื้อเองได้ ในระยะนี้ประชากรจะอยู่ในสถานะเปิดเผย (Exposed)

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 Deep Learning for COVID-19 prediction

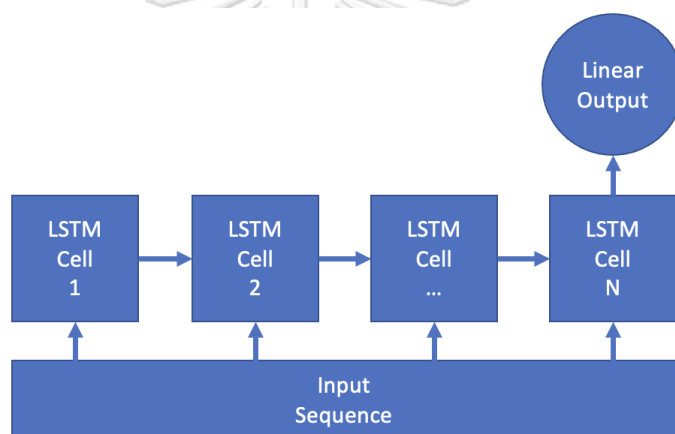
S. Bahri และคณะ [22] ได้นำเสนอการใช้โครงข่ายประสาทเทียมแบบความจำขนาดสั้นระยะยาวในการพยากรณ์จำนวนผู้หายจากการติดเชื้อสะสมในประเทศอินเดีย สหรัฐอเมริกาและอิตาลี ในอีก 7 วันข้างหน้า การทดลองข้อมูลโรคติดเชื้อโคโรนาไวรัส 2019 จากองค์การอนามัยโลกตั้งแต่วันที่ 22 มกราคม 2020 ถึงวันที่ 22 มิถุนายน 2020 ประกอบไปด้วยจำนวนผู้ติดเชื้อ จำนวนผู้เสียชีวิตและจำนวนผู้ถูกรักษาจนหายแต่ละวันแต่ละประเทศ นอกจากนี้ยังใช้ข้อมูลการติดเชื้อซาร์ส และข้อมูลทางสถิติอื่น ๆ เช่น ความหนาแน่นของประชากร ผลิตภัณฑ์มวลรวมภายในประเทศ อัตราการเสียชีวิตของเด็กทารกและอื่น ๆ การทดลองประสบความสำเร็จในการพยากรณ์โดยใช้ค่าเฉลี่ยร้อยละความผิดพลาดสัมบูรณ์เป็นมาตรวัดความผิดพลาดซึ่งการทดลองให้ค่าความผิดพลาดที่ 1.46-2.65 เปอร์เซ็นต์

2.2.2 COVID-19 Time Series Forecasting of Daily Cases, Deaths Caused and Recovered Cases using Long Short Term Memory Networks

S. Bodapati และคณะ [23] ได้นำเสนอการใช้โครงข่ายประสาทเทียมความจำขนาดสั้นระยะยาวเพื่อการพยากรณ์แนวโน้มจำนวนผู้ติดเชื้อรายใหม่ ผู้ติดเชื้อสะสม ผู้หายป่วยและผู้เสียชีวิตจากโรคติดเชื้อไวรัสโคโรนา 2019 ผู้เสนอได้พิจารณา 5 วิธีการสร้างโมเดลพยากรณ์ประกอบด้วยวิธีการพยากรณ์อนุกรมเวลาแบบดั้งเดิม เช่น ค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (ARIMA) เพอร์เซปตรอนหลายชั้น (Multi-Layer Perceptron) เครือข่ายประสาทเทียมคอนโวลูชัน

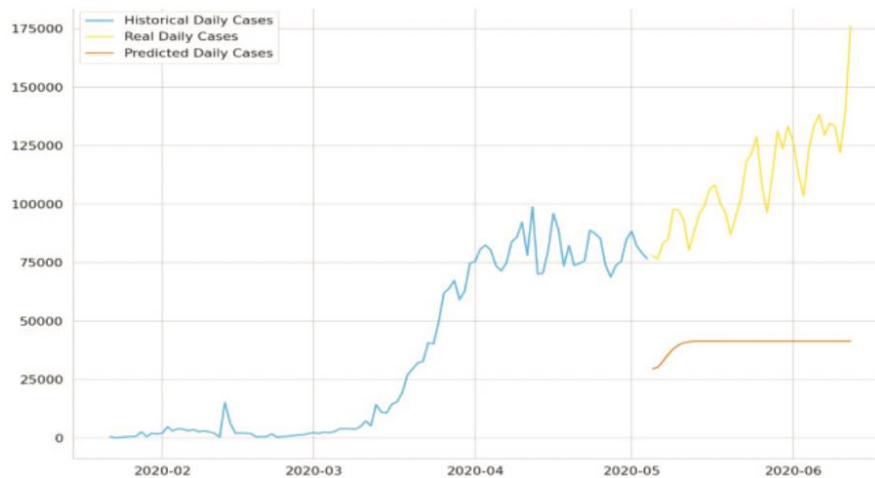
(Convolution Neural Network) เครือข่ายประสาทเทียมวนกลับ (Recurrent Neural Network) และเครือข่ายประสาทเทียมแบบผสม ผู้นำเสนอได้เลือกใช้ความจำขนาดสั้นระยะยาวซึ่งเป็นหนึ่ง รูปแบบในเครือข่ายประสาทเทียมแบบวนกลับซึ่งสามารถสร้างการเชื่อมต่อระหว่างเซลล์แบบชั่วคราว รักษาและแบ่งปันข้อมูลในเซลล์ได้เซลล์ในระดับชั้นเดียวกันได้ นอกจากนี้มันยังเป็นโครงสร้าง เครือข่ายประสาทเทียมที่สามารถเข้าใจได้ง่าย สามารถให้ผลลัพธ์นอกเหนือจากสมการเชิงเส้นได้และ ให้ผลลัพธ์ได้หลายค่าและหลากหลาย

โครงสร้างโมเดลที่ผู้นำเสนอสร้างประกอบด้วยชั้นนำเข้าซึ่งรับข้อมูลเข้าและส่งต่อให้ เครือข่ายประสาทเทียมความจำขนาดสั้นระยะยาวที่ชั้นระหว่างกลางโดยยูนิตสุดท้ายของชั้นกลางจะ ส่งต่อให้ชั้นผลลัพธ์เชิงเส้นแล้วให้ผลลัพธ์การทำนาย รูปที่ 3 แสดงโครงสร้างสถาปัตยกรรมที่นำเสนอ โดยผู้นำเสนอ



รูปที่ 3 โครงสร้างสถาปัตยกรรมที่นำเสนอโดย S. Bodapati และคณะ

ผู้นำเสนอได้สร้างโมเดลจากสถาปัตยกรรมที่กล่าวมาข้างต้นในการทำนายจำนวนผู้ติดเชื้อรายวัน ทำนายผู้ติดเชื้อในอนาคต จำนวนผู้หายจากการติดเชื้อและจำนวนผู้เสียชีวิต ในด้าน ผลลัพธ์การทำนายผู้ติดเชื้อรายวันมีความผิดพลาดสูงและไม่เป็นไปตามแนวโน้มที่เกิดขึ้นจริงตาม ที่เห็นได้จากรูปที่ 4 ด้านการพยากรณ์ผู้ติดเชื้อในอนาคต ทางผู้นำเสนอได้สร้างโมเดลจาก สถาปัตยกรรมที่นำเสนอเพื่อพยากรณ์จำนวนผู้ติดเชื้อในอีก 14 วันในอนาคต ผลลัพธ์ของโมเดลให้ ผลลัพธ์ที่มีความแม่นยำที่ 77.89 เปอร์เซ็นต์




รูปที่ 4 การทำนายผู้ติดเชื้อรายวันจากโมเดลของ S. Bodapati และคณะ

2.2.3 Deep learning via LSTM models for COVID-19 infection forecasting in India

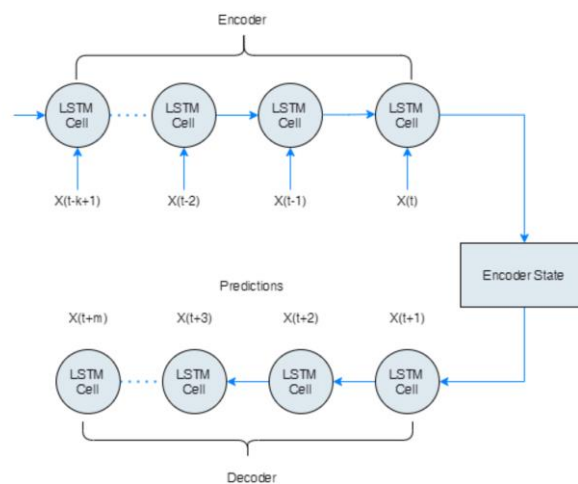
ความน่าสนใจในงานวิจัยของ R. Chandra และคณะ [24] คือการเปรียบเทียบประสิทธิภาพของสถาปัตยกรรมความจำขนาดสั้นระยะยาว ความจำขนาดสั้นระยะยาวแบบสองทิศทางและความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัสในการทำนายจำนวนผู้ติดเชื้อในประเทศอินเดีย

สถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบสองทิศทางอนุญาตให้เข้าถึงข้อมูลและผลลัพธ์ของเซลล์ถัดไปนอกเหนือจากเซลล์ก่อนหน้าทำให้เซลล์นั้นสามารถรับข้อมูลได้ทั้งสี่ทิศทางคือเซลล์ก่อนหน้าและเซลล์ถัดไปดังที่แสดงในรูปที่ 5 ในขั้นไปข้างหน้าและขั้นย้อนกลับ สถาปัตยกรรมนี้นิยมใช้ในงานด้านการประมวลผลภาษาธรรมชาติ การรู้จำเสียงพูดและการสังเคราะห์เสียงพูดเพราะสถาปัตยกรรมนี้อนุญาตให้เข้าถึงข้อมูลก่อนหน้าและข้างหลังได้ทำให้มีประสิทธิภาพมากกว่าการใช้สถาปัตยกรรมเครือข่ายประสาทวนกลับแบบอื่น ๆ



รูปที่ 5 สถาปัตยกรรมที่มีพื้นฐานจากความจำขนาดสั้นระยะยาวที่ใช้ในงานของ R. Chandra

สถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัสเป็นสถาปัตยกรรมที่รับข้อมูลอนุกรมเป็นข้อมูลขาเข้า ประมวลผลและสังเคราะห์ออกเป็นอนุกรมผลลัพธ์ที่อาจมีขนาดไม่เท่ากับอนุกรมขาเข้า การทำงานเริ่มต้นจากรับอนุกรมขาเข้า คำนวณสถานะแอบแฝงและทำอนุกรมขาเข้าให้เป็นเวกเตอร์แฝงและหาความน่าจะเป็นที่ดีที่สุดต่อการกระจายตัวของอนุกรมผลลัพธ์ต่ออนุกรมนำเข้า รูปที่ 6 แสดงถึงสถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัส สถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัสเป็นที่นิยมใช้ในการทำการแปลภาษาอัตโนมัติหรือการแปลภาษาของเครื่องเป็นต้น ตัวอย่างเช่นการแปลภาษาไทยเป็นภาษาอังกฤษด้วยเครื่อง



รูปที่ 6 สถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบเข้ารหัส-ถอดรหัส

จากการทดลอง ผู้นำเสนอสามารถสรุปได้โครงสร้างความจำขนาดสั้นระยะยาวสามารถพยากรณ์ได้ดีกว่าสถาปัตยกรรมความจำขนาดสั้นระยะยาวแบบสองทิศทางและแบบเข้ารหัส-ถอดรหัสแต่ไม่สามารถบอกได้ว่าการใช้การใช้ข้อมูลของรัฐรอบข้างเป็นข้อมูลเพิ่มเติมจะทำให้การพยากรณ์ดีกว่าการใช้ข้อมูลของรัฐ ๆ เดียว ผู้นำเสนอมองว่าการเรียนรู้ของโมเดลจำเป็นต้องใช้ข้อมูลมากกว่านี้เพื่อให้โมเดลเรียนรู้สถานการณ์ในลักษณะอื่น ๆ ที่แตกต่างออกไป



บทที่ 3

แนวคิดและวิธีการวิจัย

หนึ่งในวัตถุประสงค์ที่สำคัญของการพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนาไวรัส 2019 คือเพื่อ การปรับเปลี่ยนแผนในการรับมือการแพร่ระบาด การทำให้เครื่องมือที่ใช้ในการพยากรณ์มี ประสิทธิภาพมากยิ่งขึ้นจึงเป็นเรื่องสำคัญ นักวิจัยได้นำเสนอวิธีการพยากรณ์จำนวนผู้ติดเชื้อด้วย วิธีการต่าง ๆ ตั้งแต่การใช้เทคนิคทั่วไปที่ใช้ในการพยากรณ์ของโรค เช่น เทคนิคเอส-อี-ไอ-อาร์ เป็น ต้น และการใช้เทคนิคทางวิทยาศาสตร์คอมพิวเตอร์ โดยเฉพาะอย่างยิ่งการใช้เทคนิคการเรียนรู้ของ เครื่อง ผู้วิจัยได้สรุปตัวอย่างผลงานวิจัยที่เกี่ยวข้องไว้ที่ตารางที่ 1

ตาราง 1 ข้อมูล เทคนิค และวิธีการวัดผลของงานวิจัยที่เกี่ยวข้อง

ชื่องานวิจัย	ข้อมูลที่ใช้	เทคนิค	วิธีการวัดผล
S. Bahri et al., Deep Learning for COVID-19 prediction	<ul style="list-style-type: none"> วันที่ เขต ประเทศ จำนวนผู้ติดเชื้อ จำนวนผู้เสียชีวิต และ จำนวนการ รักษาหายจากชุดข้อมูลการติดเชื้อ ไวรัสโคโรนาจากองค์การอนามัยโลก จำนวนผู้ติดเชื้อ จำนวนผู้เสียชีวิต จำนวนการรักษาหายจากชุดข้อมูล SARS-03 จำนวนประชากรในแต่ละประเทศ ความหนาแน่นของจำนวนประชากร และ อื่น ๆ จาก ชุด ข้อมูล Demographic 	LSTM	MAPE
S. Bodapati et al., COVID-19 Time Series Forecasting of Daily Cases, Death Caused and Recovered Cases using Long Short Term Memory Networks	จำนวนผู้ติดเชื้อรายใหม่ จำนวนผู้เสียชีวิต และจำนวนการรักษาหาย	LSTM	Accuracy
I. Eksinchol, Monitoring the COVID-19 Situation in Thailand	จำนวนผู้ป่วยใหม่รายวันในแต่ละจังหวัดใน ประเทศไทยที่รายงานโดยกระทรวง สาธารณสุข	SEIR	ไม่ระบุการ วิ ช า ร วัดผล

R. Chandra, Deep learning via LSTM models for COVID-10 infection forecasting in India	จำนวนผู้ป่วยสะสม	<ul style="list-style-type: none"> • LSTM • Bi-Directional LSTM • Encoder-Decoder LSTM 	RMSE
M. Arceda et al., Forecasting time series with multiplicative trend exponential smoothing and LSTM COVID-19 case study	<ul style="list-style-type: none"> • จำนวนผู้ติดเชื้อ • อัตราการเกิดจำนวนผู้ติดเชื้อ 	<ul style="list-style-type: none"> • Multiplicative trend exponential smoothing • LSTM 	RMSE
C. J. Huang et al., Multiple-Input Deep Convolution Neural Network model for COVID-19 forecasting in China	<ul style="list-style-type: none"> • จำนวนผู้ติดเชื้อทั้งหมด • จำนวนผู้ติดเชื้อรายใหม่ • จำนวนผู้หายป่วยทั้งหมด • จำนวนผู้หายป่วยรายใหม่ • จำนวนผู้เสียชีวิตทั้งหมด • จำนวนผู้เสียชีวิตรายใหม่ 	CNN, MLP, LSTM, GRU	RMSE, MAE

จากตารางที่ 1 แสดงให้เห็นถึงความหลากหลายของชนิดข้อมูลในแต่ละงานวิจัยนั้นมีความแตกต่างกัน แต่มีข้อมูลชนิดหนึ่งที่ถูกใช้ในทุกงานวิจัยคือจำนวนผู้ติดเชื้อสะสม พร้อมกันนั้นผู้วิจัยตั้งข้อสังเกตว่านักวิจัยพยายามเพิ่มข้อมูลอื่น ๆ ที่อาจเกี่ยวข้องกับการติดเชื้อไวรัสโคโรนา 2019 เช่น จำนวนผู้เสียชีวิต จำนวนการรักษาหายและอื่น ๆ หรือกระทั่งสังเคราะห์ข้อมูลเดิมเพื่อให้ได้ข้อมูลชนิดใหม่ เช่น อัตราการเกิดจำนวนผู้ติดเชื้อ นอกเหนือจากนั้นนักวิจัยได้นำเสนอข้อมูลประชากรมาใช้ในงานวิจัยทำให้ข้อมูลมีความแม่นยำมากขึ้น นอกจากนี้ตารางที่ 1. แสดงให้เห็นว่าเทคนิคความจำขนาดสั้นระยะยาว (Long Short-Term Memory; LSTM) เป็นหนึ่งในเทคนิคยอดนิยมที่ใช้ในการพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 แต่ยังมีเทคนิคการเรียนรู้ของเครื่องอื่น ๆ ที่น่าสนใจ การทบทวนและเปรียบเทียบเทคนิคการพยากรณ์จึงเป็นอีกเรื่องหนึ่งที่ผู้วิจัยสนใจเนื่องจากอาจจะชนิดของเทคนิคอาจส่งผลต่อประสิทธิภาพการพยากรณ์ในภาพรวมอีกด้วยและตารางที่ 1 แสดงให้เห็นวิธีการวัดประสิทธิภาพของโมเดลพยากรณ์โดยวิธีการที่เป็นที่นิยมคือรากที่สองของค่าเฉลี่ยความ

ผิดพลาดกำลังสอง (Root Mean Square Error; RMSE) ทั้งนี้ผู้วิจัยสังเกตเห็นถึงปัญหาของรากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองเพราะผลลัพธ์จากฟังก์ชันนี้สามารถตีเป็นความหมายได้ยากกว่าค่าเฉลี่ยความผิดพลาดสัมบูรณ์หรือค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์ที่ตีความหมายเป็นจำนวนคนและเปอร์เซ็นต์ได้ตามลำดับ

3.1 ชุดข้อมูล

ในงานวิจัยชิ้นนี้ได้นำข้อมูลการติดเชื้อไวรัสโคโรนา 2019 จาก ourworldindata.org ระหว่างวันที่ 24 มกราคม 2020 ถึงวันที่ 11 กรกฎาคม 2021 โดยมีข้อมูลประกอบด้วย จำนวนผู้ติดเชื้อสะสม จำนวนผู้ติดเชื้อรายใหม่ จำนวนผู้เสียชีวิตสะสม จำนวนผู้เสียชีวิตรายใหม่ จำนวนการฉีดวัคซีนสะสม จำนวนการฉีดวัคซีนรายใหม่ จำนวนประชากร ในแต่ละประเทศแต่ละวัน รวมทั้งสิ้น 98 ประเทศ, ใช้ข้อมูลการเคลื่อนที่ของประชากรจาก Google community mobility report [25] และ Apple mobility trends report [26] และข้อมูลประเทศที่อยู่ติดกันจาก Geodatasource

ชุดข้อมูลประกอบด้วยข้อมูลจากประเทศอัลบาเนีย อัลจีเรีย อาร์เจนตินา อาร์เมเนีย ออสเตรเลีย ออสเตรีย อาเซอร์ไบจาน บาห์เรน บังกลาเทศ เบลารุส เบลีซ บอสเนียแอนด์เฮอร์เซโกวีนา บอตสวานา บัลแกเรีย เคปเวิร์ด แคนเมอรูน แคนาดา ชิลี จีน ไคล์มเปีย โกลด์โคสต์ โครเอเชีย ไชปรัส เช็กเกีย สาธารณรัฐประชาธิปไตยคองโก เดนมาร์ก สาธารณรัฐโดมินิกัน อียิปต์ เอลซัลวาดอร์ เอสโตเนีย ฟินแลนด์ เฟรนช์โปลินีเซีย จอร์เจีย เยอรมนี กานา กรีซฮังการี อินเดีย อินโดนีเซีย อิหร่าน (สาธารณรัฐอิสลาม) ไอร์แลนด์ อิสราเอล จอร์แดน คาซัคสถาน โคอโซโว คูเวต คีร์กีสถาน ลัตเวีย เลบานอน ลิเบีย ลิทัวเนีย เม็กซิโก มอนเตเนโกร โมร็อกโก โมซัมบิก พม่า เนเธอร์แลนด์ ไนจีเรีย มาซิโดเนียเหนือ นอร์เวย์ โอมาน ปากีสถาน ปานามา เปรู ฟิลิปปินส์ โปแลนด์ กาตาร์ สาธารณรัฐมอลโดวา โรมาเนีย รัสเซีย เซอร์เบียแอนด์มอนเตเนโกร สิงคโปร์ สโลวาเกีย สโลวีเนีย แอฟริกาใต้ สเปน ศรีลังกา สวีเดน สวิตเซอร์แลนด์ ทาจิกิสถาน ตุรกี ยูเครน สหรัฐอาหรับเอมิเรตส์ สหรัฐอเมริกา อูรุกวัย อุซเบกิสถาน เวเนซุเอลา (สาธารณรัฐโบลีเวีย)และซิมบับเว ข้อมูลที่ใช้สำหรับการทดสอบโมเดลมาจากประเทศบราซิล ไทย ญี่ปุ่น สาธารณรัฐเกาหลี เบลเยียม สหราชอาณาจักร คอสตาริกา ซาอุดีอาระเบีย อิรักและเคนยา

ผู้วิจัยได้พิจารณาข้อมูลการเคลื่อนที่ของประชากรของ Apple mobility report พบว่ามีข้อจำกัดจำนวนมาก เช่น จำนวนข้อมูลและชนิดมีน้อยกว่าข้อมูลการเคลื่อนที่ของประชากรของ Google community mobility report ซึ่งชนิดของข้อมูลมีแค่ชนิดของการเดินทาง เช่น การ

เดินทางด้วยพาหนะ และการเดินทางทางเท้าเท่านั้น ผู้วิจัยจึงเลือกใช้ข้อมูล การเคลื่อนที่ของประชากรจาก Google community mobility report ซึ่งประกอบ

1. การเคลื่อนตัวของประชากรในหมวดร้านค้าปลีกและสันนาการ หมายถึง การเคลื่อนตัวของประชากรต่อร้านอาหาร คาเฟ่ ห้างสรรพสินค้า สวนสนุก พิพิธภัณฑ์ ห้องสมุดและโรงแรม เป็นต้น

2. การเคลื่อนตัวของประชากรในหมวดร้านขายของชำและร้านยา หมายถึง การเคลื่อนตัวของประชากรต่อตลาด โกดังอาหาร ร้านขายยา เป็นต้น

3. การเคลื่อนตัวของประชากรในหมวดสวน หมายถึง การเคลื่อนตัวของประชากรต่อสวนอุทยานแห่งชาติ ชายหาด เป็นต้น

4. การเคลื่อนตัวของประชากรในหมวดสถานีขนส่ง หมายถึง การเคลื่อนตัวของประชากรต่อสถานีรถไฟใต้ดิน สถานีรถประจำทาง สถานีรถไฟ เป็นต้น

5. การเคลื่อนตัวของประชากรในหมวดสถานที่ทำงาน หมายถึง การเคลื่อนตัวของประชากรต่อสถานที่ทำงาน

6. การเคลื่อนตัวของประชากรในหมวดที่อยู่อาศัย หมายถึง การเคลื่อนตัวของประชากรต่อสถานที่พักอาศัย

ข้อมูลที่ใช้ในงานวิจัยนี้สามารถสรุปได้ในตารางที่ 2

ตาราง 2 สรุปข้อมูลที่ใช้ในงานวิจัย

ชุดข้อมูล	ชนิดข้อมูล	หน่วย
Ourworldindata.org	จำนวนผู้ติดเชื้อรายใหม่	คน
	จำนวนผู้ติดเชื้อสะสม	
	จำนวนผู้เสียชีวิตรายใหม่	
	จำนวนผู้เสียชีวิตสะสม	
Ourworldindata.org,	จำนวนการฉีดวัคซีนทั้งหมด	ต่อหนึ่งร้อยครั้ง
	จำนวนผู้ได้รับวัคซีน	
	จำนวนผู้ได้รับวัคซีนครบโดส	
Geo data source	จำนวนผู้ติดเชื้อสะสมเฉลี่ยและจากประเทศข้างเคียง	คน (ค่าเฉลี่ย)

Google community mobility report	การเคลื่อนตัวของประชากรในหมวดร้านค้าปลีกและสันนาการ	ร้อยละ
	การเคลื่อนตัวของประชากรในหมวดร้านอาหารของชำและร้านยา	
	การเคลื่อนตัวของประชากรในหมวดสวน	
	การเคลื่อนตัวของประชากรในหมวดสถานีขนส่ง	
	การเคลื่อนตัวของประชากรในหมวดสถานที่ทำงาน	
	การเคลื่อนตัวของประชากรในหมวดที่อยู่อาศัย	

3.2 การเตรียมข้อมูล

ข้อมูลจะต้องถูกทำให้สะอาดโดยผ่านหลากหลายขั้นตอนก่อนนำมาใช้งาน ในงานวิจัยชิ้นนี้มีขั้นตอนการทำความสะอาดข้อมูลดังนี้

1. การคัดเลือกข้อมูลที่น่าสนใจ งานวิจัยชิ้นนี้ นำข้อมูลของประเทศที่มีจำนวนผู้ติดเชื้อสะสมน้อยกว่า 1000 ออกไป ส่งผลให้สิ่งรบกวนจากข้อมูลที่มีค่าน้อยลดลงส่งผลให้การโมเดลเรียนรู้ได้ดีและเร็วมากขึ้น

2. การทำให้อยู่ในมาตรฐานเดียวกันด้วยการใช้ Min-Max Normalization กับชุดข้อมูลจาก Ourworldindata.com และ Google mobility report เช่น ข้อมูลจำนวนผู้ติดเชื้อรายใหม่และจำนวนผู้ติดเชื้อสะสม เป็นต้น

3. ข้อมูลการเคลื่อนที่ของประชากรจาก Google mobility report

ข้อมูลนำเข้าจะต้องอยู่ในรูปแบบเมทริกซ์ $M \times N$ โดย M มีค่าเท่ากับชนิดของข้อมูลที่จะใช้กับโมเดล และ N มีค่าเท่ากับจำนวนวันย้อนหลังของข้อมูล การใช้เทคนิค Sliding window ในการสร้างชุดข้อมูลนำเข้าทำให้สามารถสร้างได้อย่างรวดเร็วและมีประสิทธิภาพ ในรูปที่ 7 แสดงตัวอย่างการสร้างชุดข้อมูล 2 ชุดที่มีขนาด 4×5 ด้วยเทคนิค Sliding window

$$\begin{bmatrix} 0 & 1 & 1 & 2 & 4 & 7 & \dots & 10 \\ 0 & 1 & 0 & 1 & 2 & 3 & \dots & 1 \\ 0 & 0 & 0 & 0 & 1.6 & 2.5 & \dots & 4.25 \\ 0 & 1 & 1 & 2 & 4 & 7 & \dots & 10 \end{bmatrix} \longrightarrow \begin{bmatrix} 0 & 1 & 1 & 2 & 4 \\ 0 & 1 & 0 & 1 & 2 \\ 0 & 0 & 0 & 0 & 1.6 \\ 0 & 1 & 1 & 2 & 4 \end{bmatrix}$$


$$\begin{bmatrix} 0 & 1 & 1 & 2 & 4 & 7 & \dots & 10 \\ 0 & 1 & 0 & 1 & 2 & 3 & \dots & 1 \\ 0 & 0 & 0 & 0 & 1.6 & 2.5 & \dots & 4.25 \\ 0 & 1 & 1 & 2 & 4 & 7 & \dots & 10 \end{bmatrix} \longrightarrow \begin{bmatrix} 1 & 1 & 2 & 4 & 7 \\ 1 & 0 & 1 & 2 & 3 \\ 0 & 0 & 0 & 1.6 & 2.5 \\ 1 & 1 & 2 & 4 & 7 \end{bmatrix}$$

รูปที่ 7 การสร้างข้อมูลนำเข้าโดยมี $M = 4$ และ $N = 5$

การสร้างข้อมูลนำเข้าด้วยเทคนิคนี้ทำให้สามารถสร้างข้อมูลนำเข้าได้เยอะมากขึ้นส่งผลให้
 ในขั้นตอนการเรียนรู้ของ โมเดลสามารถเรียนรู้ได้มากขึ้น

3.3 การสร้างโมเดลเครือข่ายหน่วยความจำขนาดสั้นระยะยาวแบบวานิลลา (Vanilla Long Short-Term Memory)


เครือข่ายหน่วยความจำขนาดสั้นระยะยาวแบบวานิลลาคือโครงข่ายประสาทเทียมที่
 ประกอบไปด้วยเครือข่ายประสาทเทียม 3 ชั้น คือ ชั้นนำข้อมูลเข้า ชั้นเครือข่ายประสาทเทียม
 ความจำขนาดสั้นระยะยาวซึ่งเป็นชั้นหลบซ่อน และ ชั้นข้อมูลออก เป็นโครงข่ายประสาทเทียมที่มี
 ความเรียบง่ายและไม่มี ความซับซ้อน การเรียนรู้โมเดลเกิดขึ้นได้ง่ายเพราะจำนวนการเชื่อมโยงน้อย
 ทำให้การเรียนรู้ย้อนกลับ (Backpropagation) มีประสิทธิภาพมากขึ้น อีกทั้งจำนวนไฮเปอร์
 พารามิเตอร์มีจำนวนน้อยทำให้ตั้งค่าได้ง่ายขึ้น รูปที่ 8 แสดงโครงสร้างของโมเดลเครือข่ายประสาท
 เทียมหน่วยความจำขนาดสั้นระยะยาวแบบวานิลลา



รูปที่ 8 โครงสร้างโมเดล Vanilla long short-term memory

3.4 การสร้างโมเดลเครือข่ายหน่วยความจำขนาดสั้นแบบวานิลลาเกตรีเคอร์เรนต์ยูนิท (Vanilla Gated Recurrent Unit)


เช่นเดียวกับโมเดลเครือข่ายหน่วยความจำขนาดสั้นระยะยาวแบบวานิลลา โมเดลเครือข่ายหน่วยความจำขนาดสั้นแบบวานิลลาเกตรีเคอร์เรนต์ยูนิทประกอบไปด้วยชั้นเครือข่ายประสาทเทียม 3 ชั้น โดยมีเกตรีเคอร์เรนต์ยูนิท 1 ชั้นอยู่ตรงกลางระหว่างชั้นข้อมูลขาเข้าและชั้นข้อมูลออก ข้อดีของการใช้หน่วยความจำขนาดสั้นระยะยาวแบบวานิลลาคือสามารถใช้ในการทดสอบได้ง่าย ความยุ่งยากน้อย การเรียนรู้ของโมเดลเกิดขึ้นได้ง่ายเนื่องจากการส่งข้อมูลย้อนกลับ ไม่เกิดการสูญหาย (Vanishing gradient) ที่เกิดบ่อยครั้งเมื่อโมเดลมีหลายชั้น รูปที่ 9 แสดงโครงสร้างของโมเดลเครือข่ายหน่วยความจำขนาดสั้นแบบวานิลลาเกตรีเคอร์เรนต์ยูนิท



รูปที่ 9 โครงสร้างโมเดล Vanilla gated recurrent unit

3.5 การสร้างโมเดลเครือข่ายประสาทเทียมความจำขนาดสั้นระยะยาวหลายชั้น (Stacked Long Short-Term Memory)

โมเดลเครือข่ายประสาทเทียมความจำขนาดสั้นระยะยาวหลายชั้นเป็นอีกหนึ่งสถาปัตยกรรมที่ได้รับความนิยมในการแก้ไขปัญหาต่าง ๆ ที่ข้อมูลมีลักษณะเป็นลำดับและแต่ละลำดับมีความเกี่ยวข้องกัน เช่น การพยากรณ์จำนวนผู้ติดเชื้อไวรัสโคโรนา 2019 สะสม [27] และการรู้จำเสียงพูด [28] โดยลักษณะเด่นของสถาปัตยกรรมนี้คือมีเครือข่ายความจำขนาดสั้นระยะยาวหลายชั้นในชั้นซ่อน ช่วยทำให้สามารถรู้จำช่วงเวลาลักษณะอื่น ๆ ได้ รูปที่ 10 แสดงให้เห็นโครงสร้างโมเดลเครือข่ายประสาทเทียมความจำขนาดสั้นระยะยาว 2 ชั้น



รูปที่ 10 โครงสร้างสถาปัตยกรรมความจำขนาดสั้นระยะยาว 2 ชั้น

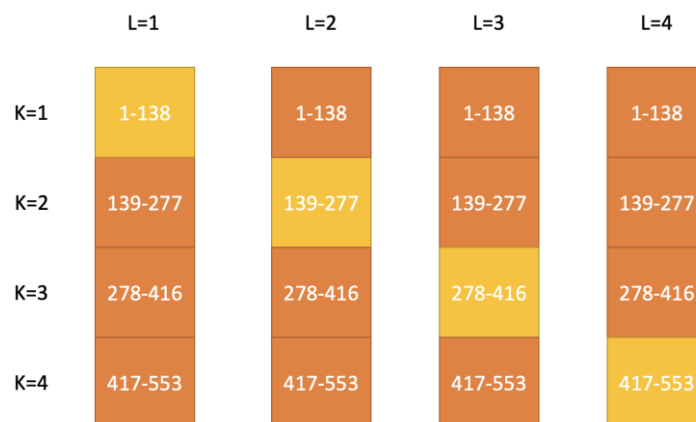
3.6 การทดสอบไขว้ข้าม K กลุ่ม

การทดสอบไขว้ข้าม K กลุ่ม (K-Fold Cross Validation) คือวิธีการยอตนิยมที่ใช้ในการตรวจสอบความมั่นคงและความอคติ (bias) ของโมเดล ด้วยปัญหาความอคติจากข้อมูลที่ใช้ในขั้นตอนการเรียนรู้ของโมเดล การเรียนรู้ด้วยข้อมูลรูปแบบเดิมซ้ำ ๆ กันจะทำให้เกิดความอคติในโมเดล ด้วยเหตุนี้ การทดสอบไขว้ข้าม K กลุ่มจะเข้ามาช่วยตรวจสอบความมั่นคงโดยการแบ่งข้อมูลออกเป็น K ส่วน จากนั้นในขั้นตอนการสอนโมเดลจะใช้ข้อมูลทั้งหมดยกเว้นชุดที่ L โดยค่า L เริ่มจาก 1 ถึง K จากนั้นในขั้นตอนตรวจสอบ (Validation) ใช้ข้อมูลชุด L ในการตรวจสอบ ตัวอย่างแสดงในรูปที่ 11 ด้วยวิธีนี้ข้อมูลที่ใช้ในขั้นตอนตรวจสอบจะเป็นข้อมูลที่ไม่ได้ผ่านขั้นตอนการเรียนรู้จึงทำให้เป็นข้อมูลที่ใช้ในการแสดงศักยภาพของโมเดลได้อย่างดีเยี่ยม แต่ต้องคำนึงถึงค่า K เพราะส่งผลต่อจำนวนข้อมูลที่ใช้ในขั้นตอนการตรวจสอบ ไม่ควรมากเกินไปหรือน้อยเกินไป




รูปที่ 11 การแบ่งข้อมูลของการทดสอบไขว้ข้าม K กลุ่ม

ข้อจำกัดในการใช้เทคนิคการทดสอบไขว้ข้าม K กลุ่มในงานที่เวลาเป็นคุณลักษณะสำคัญ อาจทำให้การทดสอบโมเดลเกิดข้อผิดพลาด ชุดคำสั่งที่มีให้เลือกใช้ในขณะนี้แบ่งกลุ่มข้อมูลด้วยการสุ่มแบบกระจายสม่ำเสมอ (Uniform Distribution) เพราะฉะนั้นการให้คำตอบของโมเดลระหว่างทำการทดสอบ โมเดลสามารถนำคำตอบจากช่วงเวลาใกล้เคียงได้ ซึ่งทำให้ประสิทธิภาพในระหว่างการทดสอบโมเดลมีค่าสูงกว่าการใช้งานจริง การทดสอบที่ใช้ในวิทยานิพนธ์นี้จึงจำเป็นต้องดัดแปลงการใช้การทดสอบไขว้ข้าม K กลุ่ม โดยให้แบบออกเป็นกลุ่มตามเวลาที่เกิดขึ้น สามารถทำได้ 2 แบบคือ การแบ่งออกตามเวลาที่เกิดขึ้นตามเวลาจริง เช่น ข้อมูลประเทศไทย มีทั้งหมด 553 ชุดเรียงตามวันที่เกิดขึ้น หากแบ่งออกเป็น 4 ส่วนจะได้ชุดข้อมูลกลุ่มที่ 1 เริ่มที่ชุดที่ 1 ถึง 138 กลุ่มที่ 2 เริ่มที่ชุด 139 ถึง 277 กลุ่มที่ 3 เริ่มที่ชุด 278 ถึง 416 และกลุ่มที่ 4 เริ่มที่ชุด 417 ถึง 553 เป็นต้น รูปที่ 12 แสดงให้เห็นการใช้เทคนิคการแบ่งกลุ่มตามเวลา



รูปที่ 12 รูปแบบการแบ่งตามเวลาเกิด

อีกรูปแบบคือการแบ่งโดยใช้การหารเอาเศษ (Modulo) โดยการหารเอาเศษของลำดับของชุดข้อมูลด้วยจำนวนกลุ่ม หากใช้ข้อมูลกลุ่มที่อยู่ติดกันในกาเรียนรู้และทดสอบ การใช้เทคนิคนี้จะเปรียบเสมือนการใช้กรอบเลื่อน (Sliding Window) ซึ่งสามารถเห็นได้จากตัวอย่างดังต่อไปนี้ แบ่งข้อมูลเป็น 7 กลุ่ม โดยใช้ 3 กลุ่มในการทดสอบ หากใช้ข้อมูลกลุ่มที่ 1 2 3 และ 4 ในการเรียนรู้ และใช้ข้อมูลกลุ่ม 5 6 และ 7 ในการทดสอบจะเห็นได้ว่า ข้อมูลชุดที่ 1 2 3 และ 4 จะถูกเรียนรู้และใช้ข้อมูลชุดที่ 5 6 และ 7 ในการทดสอบ ในขณะที่เดียวกับข้อมูลชุดที่ 8 9 10 และ 11 จะถูกใช้ในการเรียนรู้และใช้ข้อมูลชุดที่ 12 13 และ 14 ในการทดสอบ ในขณะเดียวกันสามารถเปลี่ยนกลุ่มข้อมูลทดสอบเป็นกลุ่มอื่น ๆ ที่อยู่ติดกันได้เพื่อหาค่าเฉลี่ยประสิทธิภาพของโมเดลได้ การใช้เทคนิคนี้จะต้องคำนึงถึงจำนวนกลุ่มที่ใช้ในการทดสอบ จะต้องมียุคที่ไม่ได้อยู่ติดกับกลุ่มข้อมูลที่ใช้ในการเรียนรู้เพื่อป้องกันการใช้ข้อมูลในชุดที่อยู่ใกล้เคียงกันมาเป็นคำตอบ รูปที่ 13 แสดงรูปแบบการแบ่งแบบหารเอาเศษ



	L=1	L=2	L=3	L=4
K=1	1,5,9,13,...	1,5,9,13,...	1,5,9,13,...	1,5,9,13,...
K=2	2,6,10,14	2,6,10,14	2,6,10,14	2,6,10,14
K=3	3,7,11,15,...	3,7,11,15,...	3,7,11,15,...	3,7,11,15,...
K=4	4,8,12,16,...	4,8,12,16,...	4,8,12,16,...	4,8,12,16,...

รูปที่ 13 รูปแบบการแบ่งหารเอาเศษ

บทที่ 4

การออกแบบและพัฒนาแบบจำลอง

เป้าหมายของงานวิจัยนี้ประกอบด้วยการใช้เทคนิคการเรียนรู้ของเครื่องเชิงลึก (Deep Learning) เพื่อพยากรณ์จำนวนผู้ติดเชื้อสะสมและการใช้เทคนิคการเรียนรู้ของเครื่องเชิงลึกเพื่อทำนายแนวโน้มของจำนวนผู้ติดเชื้อรายใหม่โดยใช้ข้อมูลจำนวนผู้ติดเชื้อสะสม จำนวนผู้ติดเชื้อรายใหม่ จำนวนผู้เสียชีวิต อัตราประชากรที่ติดเชื้อ อัตราการฉีดวัคซีน เส้นเฉลี่ยเคลื่อนที่ของจำนวนผู้ติดเชื้อสะสม และการเคลื่อนตัวของประชากร โดยแบ่งออกเป็น 4 การทดลองประกอบด้วย การเปรียบเทียบสถาปัตยกรรมที่เหมาะสม การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสม การทดลองทำนายแนวโน้มผู้ติดเชื้อรายใหม่ และการทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยโมเดลที่เรียนรู้จากข้อมูลแนวโน้มจำนวนผู้ติดเชื้อรายใหม่เพียงแนวโน้มชนิดเดียว การทดลองแบ่งออกเป็น 2 ประเภทคือการพยากรณ์จำนวนผู้ติดเชื้อสะสมและการพยากรณ์แนวโน้มผู้ติดเชื้อรายใหม่ ซึ่งแต่ละการทดลองแยกออกเป็น 2 โมเดลซึ่งแต่ละโมเดลมีวัตถุประสงค์แตกต่างกันคือการพยากรณ์ในวันที่ T+7 และ T+21 เมื่อ T คือวันล่าสุดในชุดข้อมูลเพื่อให้ทราบถึงประสิทธิภาพของการพยากรณ์ในระยะสั้นและระยะยาวและจะทำให้การเรียนรู้เกิดขึ้นได้ง่ายขึ้นเพราะมีเป้าหมายคือการพยากรณ์จำนวนผู้ติดเชื้อสะสมในวันใด ๆ เพียงเป้าหมายเดียว

4.1 การทดลองเปรียบเทียบสถาปัตยกรรมและจำนวนวันที่เหมาะสม

ในปัจจุบัน โครงสร้างสถาปัตยกรรมเครือข่ายประสาทเทียมมีหลากหลายรูปแบบ แต่ละรูปแบบมีวัตถุประสงค์ในการใช้งานที่แตกต่างกัน เช่น โครงข่ายประสาทเทียมหลายชั้น โครงข่ายประสาทเทียมความจำขนาดสั้นระยะยาว โครงข่ายประสาทเทียมคอนโวลูชัน เป็นต้น ทั้งนี้จากตารางที่ 1 แสดงให้เห็นว่าโครงข่ายความจำขนาดสั้นระยะยาวและโครงข่ายประสาทเทียมเกตรีเคอร์เรนต์ยูนิทเป็นโครงสร้างสถาปัตยกรรมที่ได้รับความนิยมในงานวิจัยการพยากรณ์จำนวนผู้ติดเชื้อ แสดงให้เห็นถึงความสำคัญของการเปรียบเทียบสถาปัตยกรรมก่อนนำไปใช้ในการทดลองอื่น ๆ

ขนาดของข้อมูลขาเข้าถือเป็นอีกปัจจัยที่จะส่งผลต่อประสิทธิภาพ การใช้จำนวนข้อมูลที่มากเกินไปจนความจำเป็นอาจจะทำให้ค่าพารามิเตอร์ภายในประสาทเทียมไม่ได้อยู่ในค่าที่เหมาะสมและทำให้การเรียนรู้เกิดขึ้นยากหรือการใช้ข้อมูลขาเข้าที่น้อยอาจไม่เพียงพอต่อการเรียนรู้และการตอบคำถาม

การทดลองนี้มีจุดมุ่งหมายเพื่อหาสถาปัตยกรรมการเรียนรู้เชิงลึกและจำนวนข้อมูลย้อนหลังที่เหมาะสมโดยเปรียบเทียบระหว่างสถาปัตยกรรมแบบความจำขนาดสั้นระยะยาว สถาปัตยกรรมแบบเกตรีเคอร์เรนต์ยูนิทและสถาปัตยกรรมแบบความจำขนาดสั้นระยะยาวหลายชั้น โดยในแต่ละสถาปัตยกรรม จะทดลองกับข้อมูลที่มีขนาดจำนวนผู้ติดเชื้อสะสมย้อนหลัง 10 20 30 40 และ 50 วัน และใช้การวัดผลโดยใช้ค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์เพื่อเปรียบเทียบประสิทธิภาพในแต่ละโมเดลที่มีจำนวนข้อมูลนำเข้าแตกต่างกัน การทดลองนี้จะช่วยให้ทราบถึงสถาปัตยกรรมที่และจำนวนข้อมูลย้อนหลังที่เหมาะสมที่จะถูกใช้ในการทดลองถัดไป

ตาราง 3 สภาพแวดล้อมที่ใช้ในการทดลองหาขนาดของข้อมูลและสถาปัตยกรรมที่เหมาะสม

จุดมุ่งหมาย	ค้นหาสถาปัตยกรรมและจำนวนวันย้อนหลังที่เหมาะสมที่สุด
ข้อมูลนำเข้า	เมทริกซ์ขนาด $N \times 1$ ของจำนวนผู้ติดเชื้อสะสม เมื่อ N มีแทนจำนวนวันที่ใช้ มีค่า 10 20 30 40 และ 50 ตามลำดับ
ตัวแปรต้น	รูปแบบสถาปัตยกรรมและจำนวนวันที่ใช้ในข้อมูลนำเข้า
ข้อมูลส่งออก/ตัวแปรตาม	จำนวนผู้ติดเชื้อสะสมในอีก 7 และ 21 วันข้างหน้า
สภาพแวดล้อม/ตัวแปรควบคุม	จำนวนรอบการเรียนรู้ 20 รอบ Learning Rate 0.001 และ ใช้เทคนิค การทดสอบไขว้ข้ามแบบแบ่งตามเวลาที่เกินขึ้น 4 กลุ่ม
การวัดผล	ค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์

ผลการทดลองนี้แสดงให้เห็นสถาปัตยกรรมและจำนวนวันที่เหมาะสมที่ใช้สำหรับโมเดลที่ใช้ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมในอนาคต จากตารางที่ 4 และ 5 แสดงให้เห็นว่า การใช้สถาปัตยกรรมความจำขนาดสั้นระยะยาวประกอบกับจำนวนข้อมูลย้อนหลัง 50 วันให้ผลลัพธ์การทำนายได้ใกล้เคียงที่สุดที่ 3.3 เปอร์เซ็นต์ในการทำนายในอนาคตวันที่ 7 และ 4.06 เปอร์เซ็นต์ในการทำนายในอนาคตวันที่ 21 การใช้จำนวนวัน 10 ให้ผลลัพธ์การทำนายผิดพลาดมากที่สุดโดยอยู่ที่ 2056.14 1282.79 และ 1882.1 เปอร์เซ็นต์ สำหรับการทำนายในอนาคตวันที่ 7 และ 129.03 96.68 และ 46.05 สำหรับการทำนายในอนาคตวันที่ 21 เมื่อใช้สถาปัตยกรรมความจำขนาดสั้นระยะยาว เกตรีเคอร์เรนต์ยูนิทและความจำขนาดสั้นระยะยาวหลายชั้น ตามลำดับ การใช้ข้อมูลย้อนหลัง

20 ถึง 40 วันทำให้ผลลัพธ์การทำนายมีค่าไม่แน่นอนและผันผวนอย่างมากอยู่ที่ 5.56-203.68 สำหรับการทำนายในอนาคตวันที่ 7 และ 10.27-85.36 สำหรับการทำนายในอนาคตวันที่ 21

การทดลองนี้แสดงให้เห็นว่าสถาปัตยกรรมที่เหมาะสมสำหรับการพยากรณ์จำนวนผู้ติดเชื้อสะสมในอนาคตในวันที่ 7 และ 21 คือสถาปัตยกรรมความจำขนาดสั้นระยะยาวซึ่งสอดคล้องกับผลลัพธ์จากงานวิจัยหลายงานที่กล่าวไว้ในช่วงต้น และจากการทดลองนี้ยังแสดงให้เห็นจำนวนวันที่เหมาะสมที่จะใช้ในการทำนายจำนวนผู้ติดเชื้อสะสมคือ 50 วัน ซึ่งอาจอนุมานได้ว่าจำนวนข้อมูลย้อนหลังและประสิทธิภาพมีความสัมพันธ์เป็นไปในทิศทางเดียวกัน

ตาราง 4 ตารางค่าเฉลี่ยผิดพลาดร้อยละสมบูรณ์จากการทำนายจำนวนผู้ติดเชื้อในอนาคต 7 วัน

สถาปัตยกรรม	10 วัน	20 วัน	30 วัน	40 วัน	50 วัน
LSTM	2056.14	17.5	13.64	16.38	3.3
GRU	1282.79	116.26	311.58	5.56	177.72
STACKED LSTM	1882.19	203.68	30.74	16.29	11.81

ตาราง 5 ตารางค่าเฉลี่ยผิดพลาดร้อยละสมบูรณ์จากการทำนายจำนวนผู้ติดเชื้อในอนาคต 21 วัน

สถาปัตยกรรม	10 วัน	20 วัน	30 วัน	40 วัน	50 วัน
LSTM	129.03	28.75	19.05	14.66	4.06
GRU	98.68	85.36	10.27	27.1	45.44
STACKED LSTM	46.05	46.27	23.54	37.23	10.43

4.2 การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมในแต่ละประเทศโดยใช้ข้อมูลเพิ่มเติม

ชนิดของข้อมูลที่นำเข้าไปโมเดลเพื่อให้โมเดลเรียนรู้เป็นอีกปัจจัยหนึ่งที่สำคัญในการพยากรณ์จำนวนผู้ติดเชื้อสะสม ข้อมูลเกี่ยวกับไวรัสโคโรนาในปัจจุบันมีจำนวนมหาศาลและหลากหลาย เช่น ข้อมูลการจำกัดการเดินทางหรือล็อกดาวน์ ข้อมูลการฉีดวัคซีน อัตราส่วนจำนวนผู้ติดเชื้อต่อประชากรทั้งหมด เป็นต้น นักวิจัยสามารถเลือกใช้ข้อมูลเหล่านี้เพื่อใช้เป็นข้อมูลประกอบในการเรียนรู้เพื่อเพิ่มประสิทธิภาพทำให้โมเดลสามารถพยากรณ์ได้แม่นยำมากยิ่งขึ้น ขณะเดียวกันข้อมูลบางชนิดไม่ได้ทำให้ประสิทธิภาพการทำนายดีขึ้น หน้าที่ยังทำให้ประสิทธิภาพแย่ลง จึงจำเป็นต้องใช้ชนิดข้อมูลให้ถูกต้องเพื่อให้โมเดลมีประสิทธิภาพในการพยากรณ์สูงสุด

การทดลองนี้เปรียบเทียบค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์การพยากรณ์จำนวนผู้ติดเชื้อสะสมแต่ละประเทศในอีก 7 และ 21 วันข้างหน้าด้วยข้อมูลจำนวนผู้ติดเชื้อสะสมประกอบกับข้อมูลเพิ่มเติมที่น่าสนใจ จัดออกเป็นกลุ่มเรียงตามความสัมพันธ์กับข้อมูลจำนวนผู้ติดเชื้อสะสม แบ่งออกเป็น 5 รูปแบบ แสดงให้เห็นในตารางที่ 6 ในส่วนข้อมูลนำเข้า


ตาราง 6 ความสัมพันธ์ระหว่างจำนวนผู้ป่วยสะสมและข้อมูลอื่น

	จำนวนผู้ป่วยสะสม
จำนวนผู้ป่วยสะสม	1
ค่าเฉลี่ยเคลื่อนที่ 3 วันจำนวนผู้ป่วยสะสม	0.99
จำนวนผู้เสียชีวิตสะสม	0.96
จำนวนผู้ติดเชื้อเฉลี่ยในประเทศที่ติดกัน	0.95
ร้อยละการฉีดวัคซีน	0.56
จำนวนการฉีดวัคซีนสะสม	0.56
ร้อยละผู้ได้รับวัคซีน	0.56
ร้อยละผู้ได้รับวัคซีนครบ	0.5
การฉีดวัคซีนใหม่	0.48
การเคลื่อนตัวของประชากรสู่ห้างสรรพสินค้า	0.42
การเคลื่อนตัวของประชากรสู่สถานี่ขนส่งสาธารณะ	0.29
การเคลื่อนตัวของประชากรสู่ร้านค้าและร้านยา	0.28
การเคลื่อนตัวของประชากรสู่สวนสาธารณะ	0.19
การเคลื่อนตัวของประชากรสู่ที่พักและโรงแรม	-0.31


ตาราง 7 ข้อมูลและสภาพแวดล้อมในการทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมในแต่ละประเทศ

จุดมุ่งหมาย	ข้อมูลเพิ่มเติมที่เพิ่มประสิทธิภาพการทำนายมากที่สุด
ข้อมูลนำเข้า/ตัวแปรต้น	<ul style="list-style-type: none"> รูปแบบที่ 1 เมทริกซ์ขนาด 10×1 มี 1 ชุดข้อมูลคือจำนวนผู้ติดเชื้อสะสม จำนวน 50 วัน รูปแบบที่ 2 เมทริกซ์ขนาด 10×3 มี 3 ชุดข้อมูลคือข้อมูลรูปแบบที่ 1 รวมกับจำนวนผู้ติดเชื้อสะสมเฉลี่ย 3 วันเคลื่อนที่ และ จำนวนผู้เสียชีวิตสะสม จำนวน 50 วัน รูปแบบที่ 3 เมทริกซ์ขนาด 10×4 มี 4 ชุดข้อมูลคือข้อมูล

	<p>รูปแบบที่ 2 รวมกับจำนวนผู้ป่วยสะสมเฉลี่ยในประเทศเพื่อนบ้าน จำนวน 50 วัน</p> <ul style="list-style-type: none"> รูปแบบที่ 4 เมทริกซ์ขนาด 10 x 9 มี 9 ชุดข้อมูลคือข้อมูลรูปแบบที่ 3 รวมกับอัตราการฉีดวัคซีนต่อประชากร 100 คน จำนวนการฉีดวัคซีนสะสม อัตราผู้ได้รับวัคซีนต่อ 100 คน อัตราผู้ได้รับวัคซีนครบต่อประชากร 100 คนและจำนวนการฉีดวัคซีนใหม่ จำนวน 50 วัน รูปแบบที่ 5 เมทริกซ์ขนาด 10 x 14 มี 14 ชุดข้อมูลคือข้อมูลรูปแบบที่ 4 รวมกับเปอร์เซ็นต์การเคลื่อนตัวประชากรที่มีต่อ ร้านขายของและยา สถานีขนส่งสาธารณะ ห้างสรรพสินค้า สวน และที่อยู่อาศัย จำนวน 50 วัน
ข้อมูลส่งออก/ตัวแปรตาม	จำนวนผู้ติดเชื้อสะสมในอีก 7 และ 21 วันถัดไป
สภาพแวดล้อม ตัวแปรควบคุม	โมเดลแบบ Vanilla LSTM จำนวนรอบการเรียนรู้ 5 รอบ Learning Rate 0.001 และ ใช้เทคนิคการทดสอบไขว้ข้ามแบบแบ่งตามเวลาที่เกินขึ้น 4 กลุ่ม
การวัดผล	ค่าเฉลี่ยความผิดพลาดร้อยละสมบูรณ์



รูปที่ 14 แผนภูมิเปรียบเทียบค่าความผิดพลาดร้อยละสมบูรณ์ของข้อมูลเพิ่มเติมแต่ละชนิดในการทำนายจำนวนผู้ติดเชื้อสะสมใน 7 วันข้างหน้า



รูปที่ 15 แผนภูมิเปรียบเทียบค่าความผิดพลาดร้อยละสัมบูรณ์ของข้อมูลเพิ่มเติมแต่ละชนิดในการทำนายจำนวนผู้ติดเชื้อสะสมใน 21 วันข้างหน้า

จากรูปที่ 14 และ 15 แสดงแผนภูมิความผิดพลาดร้อยละสัมบูรณ์ของการพยากรณ์จำนวนผู้ติดเชื้อสะสมในอีก 7 และ 21 วันข้างหน้าของแต่ละชุดข้อมูล ผลการทดลองแสดงให้เห็นว่าการพยากรณ์จำนวนผู้ติดเชื้อสะสมใน 7 วันข้างหน้าสามารถทำได้อยู่ในระดับเดียวกันในทุกชุดข้อมูลอยู่ที่ 3.3-6.23 เปอร์เซ็นต์ โดยชุดข้อมูลที่ทำได้ดีและแย่ที่สุดคือ ชุดที่ 1 และชุดที่ 5 ตามลำดับ การพยากรณ์จำนวนผู้ติดเชื้อสะสมในอีก 21 วันข้างหน้ามีค่าความผิดพลาดร้อยละสัมบูรณ์อยู่ในช่วง 4.06-15.64 โดยชุดข้อมูลที่ทำได้ดีและแย่ที่สุดคือ ชุดที่ 1 และชุดที่ 5 ตามลำดับ

การทดลองนี้มีสมมุติฐานว่าการใช้ข้อมูลชนิดอื่น ๆ ประกอบกับข้อมูลที่สนใจจะช่วยเพิ่มประสิทธิภาพการพยากรณ์ให้มีความแม่นยำมากขึ้น ในการพยากรณ์ไปในอนาคต 7 วันข้างหน้าสามารถทำได้แม่นยำในระดับเดียวกันแต่ในการทำนายไปในอนาคต 21 วัน เมื่อใช้ข้อมูลมากกว่า 1 ชนิดทำให้การประสิทธิภาพในการพยากรณ์แย่งลง

4.3 การทดลองพยากรณ์แนวโน้มผู้ติดเชื้อรายใหม่

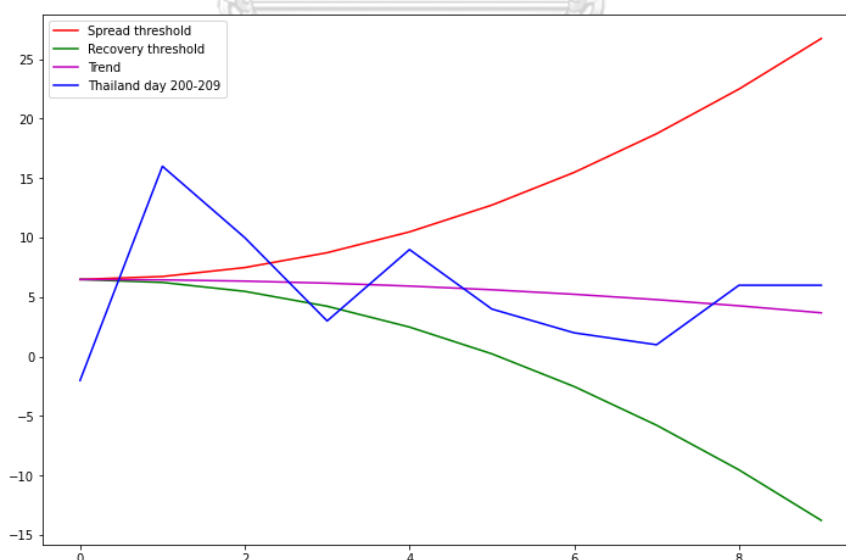
รูปแบบการเพิ่มขึ้นหรือลดลงของจำนวนผู้ติดเชื้อรายวันเป็นอีกหัวข้อที่น่าสนใจหัวข้อหนึ่ง และมีความท้าทาย การพยากรณ์จำนวนผู้ติดเชื้อรายใหม่ประจำวันสามารถทำได้ยากเพราะข้อมูล

อัตราการติดเชื้อมีความผันผวนสูง อีกทั้งยังสามารถเกิดความผิดพลาดได้ง่ายอันเนื่องมาจากการรายงานที่ผิดพลาด ข้อมูลจะต้องถูกทำให้สะอาดเพื่อกำจัดความผิดพลาด ตัวอย่างเช่น การใช้งานค่าเฉลี่ยเคลื่อนที่เพื่อแก้ปัญหาจำนวนผู้ติดเชื้อรายใหม่ประจำวันมีค่าน้อยกว่า 0 หรือมีความผันผวนสูงเป็นต้น ในทางตรงกันข้าม การพยากรณ์แนวโน้มจำนวนผู้ติดเชื้อรายใหม่รายวันในอนาคตเป็นเรื่องที่น่าสนใจ ทำได้ง่ายกว่าและมีประโยชน์กว่า เพราะการหาแนวโน้มจะแสดงทิศทางของจำนวนผู้ติดเชื้อว่าเพิ่มขึ้น คงที่ หรือลดลง ทำให้ทราบได้ว่าสถานการณ์การติดเชื้อในอนาคตจะเป็นอย่างไร

กำหนดนิยามให้แนวโน้มการเพิ่มขึ้นและลดลงของจำนวนผู้ติดเชื้อรายใหม่มีลักษณะดังสมการดังต่อไปนี้


$$f(x) = ax^2 + c$$

เมื่อ x คือจำนวนวันนับจากวันแรกที่มีข้อมูลในแต่ละประเทศและ $f(x)$ คือจำนวนผู้ติดเชื้อรายใหม่ในวันที่ x กำหนดให้ลักษณะแนวโน้มเพิ่มขึ้นเมื่อค่า a มีค่ามากกว่า 0.25 และลักษณะแนวโน้มลดลงเมื่อค่า a มีค่าน้อยกว่า -0.25 นอกเหนือจากนั้นเป็นลักษณะคงที่ รูปที่ 16 แสดงตัวอย่างข้อมูลจำนวนผู้ติดเชื้อรายใหม่ในประเทศไทยวันที่ 200 ถึง 209 นับจากวันแรกที่มีข้อมูลแนวโน้มการติดเชื้อ และเส้นแบ่งเขตระหว่างแนวโน้มเพิ่มขึ้นและแนวโน้มลดลง จากรูปข้อมูลในวันดังกล่าวมีแนวโน้มคงที่เพราะอยู่ระหว่างเส้นแนวโน้มทั้งสอง



รูปที่ 16 เส้นแบ่งระหว่างลักษณะแนวโน้มและตัวอย่างข้อมูล

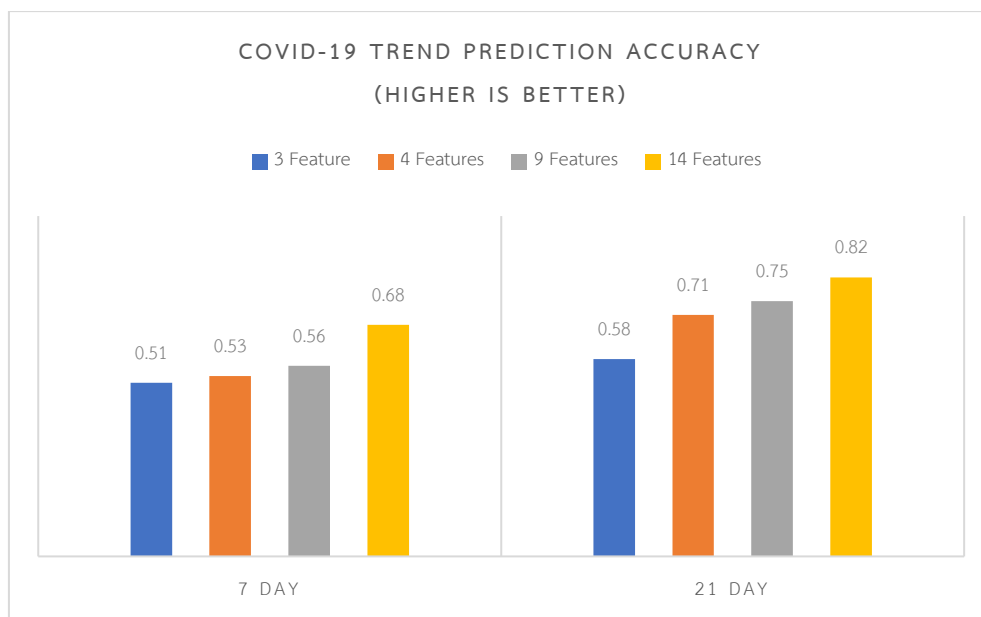
ข้อมูลนำเข้าที่ใช้ในการทดลองนี้จะใช้ข้อมูลนำเข้าที่มีลักษณะเดียวกับการทดลองที่ 4.2 บางส่วน โดยใช้ทั้งหมด 4 รูปแบบได้แก่รูปแบบที่ 2 3 4 และ 5 เพื่อเปรียบเทียบประสิทธิภาพข้อมูล แต่ละรูปแบบ



รูปที่ 17 ตัวอย่างสถาปัตยกรรมที่ใช้ในการจำแนกแนวโน้มการเพิ่มขึ้นของผู้ติดเชื้อ

โครงสร้างสถาปัตยกรรมที่ใช้ในการทดลองเป็นไปดังรูปที่ 19 ประกอบด้วยชั้นรับข้อมูลที่รับข้อมูลเมทริกซ์ขนาด $10 \times N$ เมื่อ N คือจำนวนชนิดของข้อมูลจำนวน 10 วัน ส่งต่อให้โครงสร้างความจำขนาดสั้นระยะยาวและ Fully Connected ที่ใช้ฟังก์ชัน Sigmoid เป็น Activation function ในชั้นซ่อนจำนวน 12 โหนดและส่งต่อไปยัง Fully Connected ในชั้นผลลัพธ์ซึ่งมีค่าออกมาได้ 3 ค่าแต่จะใช้ Softmax เป็น Activation function ทำให้มีผลลัพธ์ออกมาเพียงหนึ่งค่า คือค่าที่มากที่สุดจาก 3 ค่า ซึ่งเป็นชนิดของแนวโน้มที่โมเดลพยากรณ์ออกมา

การแบ่งข้อมูลที่ใช้สำหรับการเรียนรู้และการทดสอบโมเดลใช้การแบ่งแบบ หารเอาเศษ โดยแบ่งออกเป็น 12 กลุ่ม การแบ่งแบบหารเอาเศษจะไม่ทำให้ข้อมูลชนิดชนิดหนึ่งชนิดใดมีจำนวนมากเกินไปเพื่อป้องกันการเกินชนิดของแนวโน้มที่ไม่สมดุลและนำไปสู่การเกิดโมเดลที่มีความอคติแตกต่างจากการแบ่งแบบตามเวลาที่อาจเกิดอคติในช่วงเวลาแรกเนื่องจากการแพร่ระบาดยังไม่ได้เริ่มขึ้น



รูปที่ 18 แผนภูมิความแม่นยำการทำนายแนวโน้มในอนาคต

จากรูปที่ 18 แสดงแผนภูมิผลการทดลองการใช้ข้อมูลในรูปแบบต่าง ๆ เพื่อเรียนรู้แนวโน้มจำนวนผู้ติดเชื้อประจำวันในการพยากรณ์ไป 7 และ 21 วันในอนาคต ในการพยากรณ์ไปในอนาคต 7 วัน การใช้ข้อมูล 3 4 9 และ 14 ชนิดสามารถทำนายได้ถูกต้อง 51 53 56 และ 68 เปอร์เซ็นต์ตามลำดับและการพยากรณ์ไปในอนาคต 21 วัน การใช้ข้อมูล 3 4 9 และ 14 ชนิดสามารถทำนายได้ถูกต้อง 58 71 75 และ 82 เปอร์เซ็นต์ตามลำดับ โดยชุดข้อมูล 14 ชนิดทำได้ดีที่สุดทั้งการพยากรณ์ในไปในอนาคต 7 และ 21 วัน และชุดข้อมูล 3 ชนิดมีความแม่นยำน้อยที่สุดเมื่อพยากรณ์ไปในอนาคต 7 และ 21 วัน

การทดลองนี้แสดงให้เห็นว่าการใช้ข้อมูลเพิ่มเติมทั้ง 14 ชนิดช่วยเพิ่มประสิทธิภาพการพยากรณ์แนวโน้มผู้ติดเชื้อ 7 และ 21 วัน ในอนาคตอย่างมีนัยสำคัญ อีกหนึ่งตัวบ่งชี้ที่แสดงให้เห็นความแตกต่างของประสิทธิภาพระหว่างการพยากรณ์แนว 7 วัน และ 21 วันคือขนาดความยาวของข้อมูล เพราะการบ่งชี้ลักษณะแนวโน้มเมื่อข้อมูลมีขนาด 21 วันทำได้ง่ายกว่าข้อมูลที่มีขนาด 7 วัน เนื่องจากจำนวนข้อมูลที่เยอะกว่า

4.4 การทดลองพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยโมเดลที่เรียนรู้จากข้อมูลแนวโน้มเดียว

แนวโน้มการแพร่ระบาดของโรคติดเชื้อไวรัสโคโรนา 19 รายวันสามารถถูกจำแนกออกเป็นแนวโน้มประกอบด้วย ข้อมูลแนวโน้มเพิ่มขึ้น ข้อมูลแนวโน้มคงที่ และ ข้อมูลแนวโน้มลดลง ข้อมูลในแต่ละแนวโน้มมีรูปแบบที่เหมือนและแตกต่างกัน การทดลองนี้เป็นการให้โมเดลได้เรียนรู้เพื่อทำนายจำนวนผู้ติดเชื้อสะสมในอนาคตอีก 7 และ 21 วันโดยโมเดลจะได้เรียนรู้จากข้อมูลที่มีจำนวนติดเชื้อรายวันเป็นแนวโน้มใดแนวโน้มหนึ่งเท่านั้น ข้อมูลที่ใช้ในการทดลองนี้ยังคงถูกแบ่งออกเป็น 5 รูปแบบเหมือนกับการทดลองที่ 4.2 วัดประสิทธิภาพโดยใช้ค่าความผิดพลาดเฉลี่ยร้อยละสมบูรณ์ การทดลองนี้จะทำให้ทราบว่า การเรียนรู้ด้วยข้อมูลแนวโน้มใดแนวโน้มหนึ่งจะส่งผลต่อประสิทธิภาพการพยากรณ์หรือไม่และอย่างไร

ตาราง 8 ค่าความผิดพลาดเฉลี่ยร้อยละสมบูรณ์ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยข้อมูลแนวโน้มจำนวนผู้ติดเชื้อรายวันชนิดเดียวกันในอีก 7 วันข้างหน้า

แนวโน้มของผู้ติดเชื้อ	รูปแบบที่ 1	รูปแบบที่ 2	รูปแบบที่ 3	รูปแบบที่ 4	รูปแบบที่ 5
แนวโน้มคงที่	3135.01	1454.82	1873.93	878.25	1655.38
แนวโน้มเพิ่มขึ้น	14.86	55.62	43.07	21.23	40.76
แนวโน้มลดลง	7.82	8.72	20.2	31.34	12.95

ตาราง 9 ค่าความผิดพลาดเฉลี่ยร้อยละสมบูรณ์ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยข้อมูลแนวโน้มจำนวนผู้ติดเชื้อรายวันชนิดเดียวกันในอีก 21 วันข้างหน้า

แนวโน้มของผู้ติดเชื้อ	รูปแบบที่ 1	รูปแบบที่ 2	รูปแบบที่ 3	รูปแบบที่ 4	รูปแบบที่ 5
แนวโน้มคงที่	138.55	40.93	31.09	64.16	47.32
แนวโน้มเพิ่มขึ้น	46.39	40.28	68.16	384.42	26.09
แนวโน้มลดลง	8.91	9.14	9.3	10.46	17.91

จากตาราง 8 และ 9 แสดงค่าความผิดพลาดเฉลี่ยร้อยละสมบูรณ์ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมด้วยข้อมูลจำนวนผู้ติดเชื้อรายวันแนวโน้มเดียวกันในอีก 7 และ 21 วันข้างหน้า การเรียนรู้ด้วยชุดข้อมูลแนวโน้มคงที่เพื่อพยากรณ์ไปในอีก 7 วันข้างหน้าสามารถพยากรณ์โดยมีค่าความผิดพลาดร้อยละสมบูรณ์อยู่ที่ 3135.01 1454.82 1873.93 878.2 และ 1655.38 ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับและในการเรียนรู้ด้วยชุดข้อมูลแนวโน้มคงที่เพื่อพยากรณ์ไปใน

อีก 21 วันข้างหน้ามีค่าความผิดพลาดร้อยละสัมบูรณ์อยู่ที่ 138.55 50.93 31.09 64.16 และ 47.32 เปอร์เซนต์ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับ จากผลลัพธ์ทำให้ทราบว่าผลการพยากรณ์จำนวนผู้ติดเชื้อสะสมไปในอนาคตวันที่ 21 เมื่อข้อมูลในอนาคตเป็นแนวโน้มคงที่ทำได้ดีกว่าการพยากรณ์ไปในอนาคตวันที่ 7 และเมื่อมีข้อมูลมากกว่า 1 รูปแบบจะสามารถพยากรณ์ได้ดีกว่า การเรียนรู้ด้วยชุดข้อมูลแนวโน้มเพิ่มขึ้นเพื่อพยากรณ์ไปในอีก 7 วันข้างหน้าสามารถพยากรณ์โดยมีค่าผิดพลาดร้อยละสัมบูรณ์อยู่ที่ 14.86 55.62 43.07 21.23 และ 40.76 ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับและในการเรียนรู้ด้วยชุดข้อมูลแนวโน้มเพิ่มขึ้นเพื่อพยากรณ์ไปในอีก 21 วันข้างหน้ามีค่าความผิดพลาดร้อยละสัมบูรณ์อยู่ที่ 46.39 40.28 68.16 384.42 และ 26.09 ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับ ผลลัพธ์แสดงให้เห็นความไม่แน่นอนของประสิทธิภาพการพยากรณ์ต่อจำนวนข้อมูลและระยะในการพยากรณ์ การใช้ข้อมูลหลากหลายชนิดไม่ได้เพิ่มหรือลดประสิทธิภาพในการพยากรณ์ทั้งการพยากรณ์ไปในอนาคตวันที่ 7 และ 21 ส่วนสุดท้ายคือการเรียนรู้ด้วยชุดข้อมูลแนวโน้มลดลงเพื่อพยากรณ์ไปในอีก 7 วันข้างหน้าสามารถพยากรณ์โดยมีค่าผิดพลาดร้อยละสัมบูรณ์อยู่ที่ 7.82 8.72 20.2 31.34 และ 12.95 ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับและในการเรียนรู้ด้วยชุดข้อมูลแนวโน้มลดลงเพื่อพยากรณ์ไปในอีก 21 วันข้างหน้ามีค่าความผิดพลาดร้อยละสัมบูรณ์อยู่ที่ 8.91 9.14 9.3 10.46 และ 17.91 ด้วยชุดข้อมูลรูปแบบที่ 1 2 3 4 และ 5 ตามลำดับ ผลการทดลองแสดงให้เห็นว่าการเพิ่มจำนวนชนิดข้อมูลส่งผลให้ประสิทธิภาพการทำนายแย่ง นอกเหนือจากนี้ ผลการทดลองยังแสดงให้เห็นว่าการพยากรณ์จำนวนผู้ติดเชื้อสะสมในอนาคตสามารถทำได้ยากเมื่อจำนวนผู้ติดเชื้อรายใหม่มีแนวโน้มคงที่และทำได้ง่ายที่สุดเมื่อผู้ติดเชื้อรายใหม่มีแนวโน้มลดลง

บทที่ 5

สรุปผลการวิจัย

5.1 สรุปผลการวิจัย

งานวิจัยชิ้นนี้แสดงให้เห็นวิธีการใช้เครือข่ายประสาทเทียมรูปแบบต่าง ๆ และการเรียนรู้เชิงลึก ในการพยากรณ์ผู้ติดเชื้อสะสมและแนวโน้มจำนวนผู้ติดเชื้อสะสมในแต่ละประเทศ การทดลองเริ่มต้นด้วยการหาขนาดข้อมูลย้อนหลังและสถาปัตยกรรมที่เหมาะสม ในการพยากรณ์จำนวนผู้ติดเชื้อในอนาคต การทดลองนี้แสดงให้เห็นถึงศักยภาพของสถาปัตยกรรมความจำขนาดสั้นระยะยาว (LSTM) ซึ่งสามารถพยากรณ์จำนวนผู้ติดเชื้อได้ดีที่สุด สอดคล้องกับงานวิจัยอื่นหลาย ๆ งานวิจัยที่ได้ใช้สถาปัตยกรรมนี้ในการพยากรณ์จำนวนผู้ติดเชื้อในอนาคต นอกจากนี้ผลการทดลองยังแสดงให้เห็นถึงขนาดข้อมูลย้อนหลังที่เหมาะสมสำหรับการพยากรณ์จำนวนผู้ติดเชื้อในอนาคต ระยะเวลาที่ทำให้ประสิทธิภาพการพยากรณ์ที่ดีที่สุดคือ 50 วัน จากการทดลองเพิ่มเติมพบว่าการใช้ข้อมูลย้อนหลัง 70 วันสามารถทำนายด้วยประสิทธิภาพได้สูงโดยมีค่าความผิดพลาดเฉลี่ยสัมบูรณ์ร้อยละอยู่ที่ 2.54 เปอร์เซ็นต์ การทดลองนี้สามารถสรุปได้ว่าประสิทธิภาพของการพยากรณ์ขึ้นอยู่กับจำนวนข้อมูลย้อนหลัง

ผู้วิจัยนำโครงสร้างสถาปัตยกรรมและขนาดระยะเวลาของข้อมูลที่ดีที่สุดจากการทดลองที่ 4.1 ไปใช้ในการทดลองต่อไปคือการทดลองการใช้ข้อมูลที่น่าสนใจเพิ่มเติม เช่น ข้อมูลการฉีดวัคซีน ข้อมูลการแพร่ระบาดในประเทศข้างเคียงและข้อมูลการเคลื่อนไหวตัวของประชากร เป็นต้น ในการพยากรณ์จำนวนผู้ติดเชื้อสะสมในแต่ละประเทศในอีก 7 วันข้างหน้าสามารถทำได้ดีในระดับเดียวกันโดยมีโมเดลที่ใช้ข้อมูลผู้ติดเชื้อสะสมเพียงอย่างเดียวทำได้ดีกว่าเล็กน้อยประมาณ 1-3 % และในการพยากรณ์ใน 21 วันข้างหน้าการใช้ข้อมูลผู้ติดเชื้อสะสมเพียงอย่างเดียวมาใช้ในการเรียนรู้ของโมเดลให้ผลลัพธ์การพยากรณ์ที่ดีที่สุด ผู้วิจัยได้สังเกตเห็นว่าจำนวนชนิดของข้อมูลที่มากขึ้นจะแปรผกผัน ประสิทธิภาพการพยากรณ์ซึ่งเป็นไปดังรูปที่ 15 และ 16 ผู้วิจัยตั้งข้อสังเกตโดยพิจารณาร่วมกับการทดลองที่ 4.3 ผลลัพธ์การพยากรณ์จำนวนผู้ติดเชื้อด้วยข้อมูลหลากหลายชนิดส่งผลแยกกว่าอาจมีผลมาจากการแบ่งข้อมูลในการเรียนรู้และทดสอบซึ่งการทดลองที่ 4.2 เป็นการใช้การแบ่งแบบตามระยะเวลาเกิด ค่าผลลัพธ์จากการพยากรณ์ในช่วงทดสอบจะอ้างอิงค่าเฉลี่ยของข้อมูลขาเข้าที่ใช้ในการเรียนรู้เมื่อค่าของข้อมูลขาเข้าที่ใช้ในการเรียนรู้มีค่าใกล้เคียงกัน การแบ่งข้อมูลตามระยะเวลาเกิดทำให้โมเดลไม่ได้เรียนรู้ข้อมูลที่เกิดขึ้นในช่วงเวลาหนึ่ง ๆ ไป ประกอบกับชนิดข้อมูลมีจำนวนมากทำ

ให้โมเดลไม่สามารถหาชุดข้อมูลที่คล้ายคลึงกันได้มากจึงเป็นเหตุให้ผลลัพธ์การพยากรณ์ของโมเดลที่รับข้อมูลหลากหลายชนิดมีค่าความผิดพลาดมากกว่า การทดลองสนับสนุนพบว่าหากแบ่งข้อมูลออกด้วยรูปแบบการเอาเศษ ค่าความผิดพลาดสัมบูรณ์ร้อยละการพยากรณ์ของโมเดลที่ใช้ชุดข้อมูลที่ 1 สามารถทำได้ที่ 27.94 เปอร์เซ็นต์ และค่าความผิดพลาดสัมบูรณ์ร้อยละการพยากรณ์ของโมเดลที่ใช้ชุดข้อมูลที่ 5 สามารถทำได้ที่ 20.57 เปอร์เซ็นต์ จะเห็นได้ว่าข้อมูลที่ 5 ทำได้ดีกว่าข้อมูลที่ 1 อยู่ 7.37 เปอร์เซ็นต์

การทดลองที่ 4.3 เป็นอีกหนึ่งการทดลองที่น่าสนใจ การพยากรณ์จำนวนผู้ติดเชื้อรายวันสามารถทำได้ยากอย่างที่กล่าวไว้ข้างต้น การพยากรณ์แนวโน้มจึงเป็นสิ่งที่น่าสนใจและเกิดขึ้นได้จริงในทางปฏิบัติ การทดลองนี้มีจุดมุ่งหมายคือการสร้างโมเดลที่สามารถตอบได้ว่าในอีก 7 และ 21 วันข้างหน้าแนวโน้มของผู้ติดเชื้อรายวันจะเป็นอย่างไร ใช้รูปแบบการแบ่งข้อมูลแบบการเอาเศษแทนการแบ่งตามเวลาเกิด ส่งผลให้เกิดคุณสมบัติการเลื่อน (Sliding Window) ในชุดข้อมูล ซึ่งส่งผลต่อการเรียนรู้ของโมเดลอย่างมีนัยยะสำคัญ ผู้วิจัยได้ทำการทดลองเพิ่มเติมซึ่งสามารถสรุปได้ว่าการแบ่งข้อมูลเป็นแบบตามเวลาเกิดไม่สามารถทำให้โมเดลเกิดการเรียนรู้ได้ โดยมีความแม่นยำอยู่ที่ 40-50 เปอร์เซ็นต์เท่านั้นเมื่อใช้ชุดข้อมูลนำเข้ารูปแบบที่ 1 2 3 4 และ 5 ผลลัพธ์การทดลองทำให้ทราบว่า การแบ่งข้อมูลแบบการเอาเศษประกอบกับการใช้ข้อมูลรูปแบบที่ 5 ทำให้โมเดลสามารถพยากรณ์ได้แม่นยำสูงสุดถึง 82 เปอร์เซ็นต์เมื่อใช้ข้อมูลย้อนหลัง 10 วันและสามารถเร่งได้สูงสุดถึง 85 เปอร์เซ็นต์เมื่อใช้ข้อมูลย้อนหลัง 50 วัน การทดลองสามารถสรุปได้ดีกว่าการใช้ข้อมูลที่เกี่ยวข้องกับข้อมูลจำนวนผู้ติดเชื้อสะสมหลากหลายชนิดช่วยเพิ่มประสิทธิภาพการพยากรณ์ได้

ในการทดลองสุดท้ายคือการทดลองให้โมเดลพยากรณ์จำนวนผู้ติดเชื้อสะสมในอีก 7 และ 21 วันข้างหน้าโดยใช้ข้อมูลแนวโน้มจำนวนผู้ติดเชื้อรายใหม่แนวโน้มเดียว ประกอบด้วยแนวโน้มเพิ่มขึ้นคงที่และลดลง จากการทดลองนี้ทำให้ทราบว่ารูปแบบแนวโน้มคงที่สามารถพยากรณ์ให้ใกล้เคียงได้ยากที่สุดไม่ว่าจะใช้กลุ่มข้อมูลรูปแบบใดก็ตามและแนวโน้มลดลงเป็นแนวโน้มที่สามารถพยากรณ์จำนวนผู้ติดเชื้อสะสมได้ง่ายที่สุด

5.2 งานวิจัยในอนาคต

การต่อยอดงานวิจัยนี้เป็นเรื่องที่น่าสนใจและท้าทาย เนื่องจากยังมีสมมุติฐานและเทคนิคต่าง ๆ ที่สามารถใช้ควบคู่และแก้ปัญหาได้ หรือแม้กระทั่งการแก้ปัญหาใหม่ ๆ ที่เกี่ยวข้องกับโรคระบาดนี้ การใช้ข้อมูลในมิติต่าง ๆ ที่น่าสนใจ ตัวอย่างเช่น ข้อมูลการลือกตาวัน ชนิดของวัคซีนที่ฉีด เป็นต้น การใช้

ข้อมูลที่เป็นปัจจุบัน การใช้เทคนิคเครือข่ายประสาทเทียมแบบผสมผสานหรือการแยกโมเดลออกตามแต่ละชนิดข้อมูลและนำไปประกอบกันในขั้นตอนสุดท้ายเพื่อเพิ่มประสิทธิภาพการพยากรณ์



บรรณานุกรม

1. Kermack, W.O. and A.G. McKendrick, *A contribution to the mathematical theory of epidemics*. Proceedings of the royal society of london. Series A, Containing papers of a mathematical and physical character, 1927. **115**(772): p. 700-721.
2. Yawney, J. and S.A. Gadsden, *A study of the COVID-19 impacts on the Canadian population*. IEEE Access, 2020. **8**: p. 128240-128249.
3. Bahloul, M.A., A. Chahid, and T.-M. Laleg-Kirati, *Fractional-order SEIQRDP model for simulating the dynamics of COVID-19 epidemic*. IEEE Open Journal of Engineering in Medicine and Biology, 2020. **1**: p. 249-256.
4. Di Giamberardino, P., et al., *Dynamical evolution of COVID-19 in Italy with an evaluation of the size of the asymptomatic infective population*. IEEE Journal of Biomedical and Health Informatics, 2020. **25**(4): p. 1326-1332.
5. Andreas, A., et al. *Modified machine learning Techique for curve fitting on regression models for COVID-19 projections*. in *2020 IEEE 25th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)*. 2020. IEEE.
6. Rustam, F., et al., *COVID-19 future forecasting using supervised machine learning models*. IEEE access, 2020. **8**: p. 101489-101499.
7. Gupta, V.K., et al., *Prediction of COVID-19 confirmed, death, and cured cases in India using random forest model*. Big Data Mining and Analytics, 2021. **4**(2): p. 116-123.
8. Saleh, A.Y. and L. Baiwei. *Dengue Prediction Using Deep Learning with Long Short-Term Memory*. in *2021 1st International Conference on Emerging Smart Technologies and Applications (eSmarTA)*. 2021. IEEE.
9. Mudele, O., et al., *Dengue vector population forecasting using multisource earth observation products and recurrent neural networks*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021. **14**: p. 4390-4404.
10. Istaiteh, O., et al. *Machine learning approaches for covid-19 forecasting*. in *2020*

International Conference on Intelligent Data Science Technologies and Applications (IDSTA). 2020. IEEE.

11. Zheng, N., et al., *Predicting COVID-19 in China using hybrid AI model*. IEEE transactions on cybernetics, 2020. **50**(7): p. 2891-2904.
12. Iqbal, M., et al., *Covid-19 patient count prediction using LSTM*. IEEE Transactions on Computational Social Systems, 2021. **8**(4): p. 974-981.
13. Ritchie, H., et al., *Statistics and Research-Coronavirus Pandemic (COVID-19)*. *Our World in Data*. 2021. 2021.
14. Lim, C., *Country Borders*. 2019: <https://github.com/geodatasource/country-borders>.
15. Hochreiter, S. and J. Schmidhuber, *Long short-term memory*. Neural computation, 1997. **9**(8): p. 1735-1780.
16. Gers, F.A. and E. Schmidhuber, *LSTM recurrent networks learn simple context-free and context-sensitive languages*. IEEE transactions on neural networks, 2001. **12**(6): p. 1333-1340.
17. Gers, F.A., N.N. Schraudolph, and J. Schmidhuber, *Learning precise timing with LSTM recurrent networks*. Journal of machine learning research, 2002. **3**(Aug): p. 115-143.
18. Sundermeyer, M., H. Ney, and R. Schlüter, *From feedforward to recurrent LSTM neural networks for language modeling*. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2015. **23**(3): p. 517-529.
19. Chiu, C.-C., et al. *State-of-the-art speech recognition with sequence-to-sequence models*. in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2018. IEEE.
20. Chen, K., Y. Zhou, and F. Dai. *A LSTM-based method for stock returns prediction: A case study of China stock market*. in *2015 IEEE international conference on big data (big data)*. 2015. IEEE.
21. Cho, K., et al., *Learning phrase representations using RNN encoder-decoder for statistical machine translation*. arXiv preprint arXiv:1406.1078, 2014.
22. Bahri, S., M. Kdayem, and N. Zoghلامي. *Deep Learning for COVID-19 prediction*. in *2020 4th International Conference on Advanced Systems and Emergent*

- Technologies (IC_ASET)*. 2020. IEEE.
23. Bodapati, S., H. Bandrupally, and M. Trupthi. *COVID-19 time series forecasting of daily cases, deaths caused and recovered cases using long short term memory networks*. in *2020 IEEE 5th International Conference on Computing Communication and Automation (ICCCA)*. 2020. IEEE.
 24. Chandra, R., A. Jain, and D. Singh Chauhan, *Deep learning via LSTM models for COVID-19 infection forecasting in India*. PloS one, 2022. **17**(1): p. e0262708.
 25. Google, *Google COVID-19 Community Mobility Reports*. 2021: <https://www.google.com/covid19/mobility>.
 26. Apple, *Apple Mobility Trends Reports*. 2021: <https://covid19.apple.com/mobility>.
 27. Devaraj, J., et al., *Forecasting of COVID-19 cases using deep learning models: Is it reliable and practically significant?* Results in Physics, 2021. **21**: p. 103817.
 28. Graves, A., A.-r. Mohamed, and G. Hinton. *Speech recognition with deep recurrent neural networks*. in *2013 IEEE international conference on acoustics, speech and signal processing*. 2013. IEEE.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	ทศพล นวลช่วย
วัน เดือน ปี เกิด	27 กันยายน 2536
สถานที่เกิด	สงขลา ประเทศไทย
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต มหาวิทยาลัยสงขลานครินทร์
ที่อยู่ปัจจุบัน	85 ซอย 1 ทุ่งรี ต.คอหงส์ อ.หาดใหญ่ จ.สงขลา



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY