



บันทึกข้อความ

ส่วนราชการ...มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก เขตพื้นที่จักรพงษ์สุวรรณารณ โทร. ๐-๒๖๙๒-๒๓๖๐...

ที่...อว.๐๖๕๑.๒๐๘(๑)/๑๔๖๒...วันที่...๔ กรกฎาคม ๒๕๖๖

เรื่อง...ขอส่งแบบอนุมัติรางวัลแก่นักวิจัยที่มีผลงานวิจัยตีพิมพ์ในวารสารวิชาการระดับชาติและระดับนานาชาติ...

เรียน ประธานคณะกรรมการบริหารกองทุนมหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

ด้วย คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก มีความประสงค์ขออนุมัติรางวัลแก่นักวิจัยที่มีผลงานวิจัยตีพิมพ์ในวารสาร/บทความวิชาการระดับชาติ และระดับนานาชาติ จำนวน ๑ ราย ได้แก่ นายสายัณห์ เทพแดง ที่มีบทความวิจัยตีพิมพ์ประเภทบทความวารสารวิชาการที่ปรากฏในฐานข้อมูล TCI ๑ (ระดับนานาชาติ) ปี พ.ศ. ๒๐๒๓ นั้น

ในการนี้ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ ขอนำส่งเอกสารเพื่อขออนุมัติรางวัลแก่นักวิจัยที่มีผลงานวิจัยตีพิมพ์ในวารสาร/บทความวิชาการระดับชาติและระดับนานาชาติ ตามเอกสารที่แนบพร้อมนี้

ลำดับ	ชื่อบทความวิจัย	ชื่อ - นามสกุล นักวิจัย	ระดับบทความ	จำนวนเงิน
๑	การจำแนกผู้ป่วยโรคเบาหวานด้วย ใช้วิธีการเรียนรู้ด้วยเครื่องโดยการ หาปัจจัยการคัดเลือกคุณลักษณะ	นายสายัณห์ เทพแดง	นานาชาติ	๖,๐๐๐

จึงเรียนมาเพื่อโปรดพิจารณา

นางสาวละออศรี เหนียงแจ่ม

(นางสาวละออศรี เหนียงแจ่ม)

คณบดีคณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ

มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก



แบบขออนุมัติรางวัลแก่นักวิจัยที่มีผลงานวิจัยตีพิมพ์ในวารสารวิชาการ

ระดับชาติและระดับนานาชาติ 1462

ชื่อการประชุมวิชาการ/วารสารวิชาการ วารสารวิชาการ มทร. สุวรรณภูมิ

ชื่อบทความ (ไทย) การจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่องโดยการหาปัจจัยการคัดเลือกคุณลักษณะ

ชื่อบทความ (อังกฤษ) The classification of diabetic patients using machine learning method by feature selection

ประเภทบทความ การประชุมวิชาการ วันที่จัดการประชุม _____
นำเสนอใน session ที่ _____ เวลา _____ วันที่ _____ เทคนิคการรายงานวารสารปริทัศน์ วารสารวิชาการที่ปรากฏในฐานข้อมูล TCI 1 TCI 2 SCOPUS (Q1,2) SCOPUS (Q3,4) ISI อนุสิทธิบัตร เลขที่อนุสิทธิบัตร _____ สิทธิบัตร เลขที่สิทธิบัตร _____ระดับบทความ ระดับชาติ ระดับนานาชาติ

ตีพิมพ์เผยแพร่ หน้า 29-44 Vol. 11(1) ปี พ.ศ. 2023

ลำดับที่	ชื่อผู้แต่ง / ผู้ร่วมแต่ง	จำนวนเงิน (บาท)	ลายมือชื่อ
1	นายสายัณห์ เทพแดง	6,000	สายัณห์ เทพแดง
		-	
	รวมเป็นเงิน(ตัวหนังสือ)(หกพันบาทถ้วน)	6,000	

สายัณห์ เทพแดง ผู้ยื่นเรื่อง

(นายสายัณห์ เทพแดง)

วันที่ ____ / ____ / ____

หัวหน้าสาขาวิชา

(นายสุทธิรักษ์ สุขเชชม)

วันที่ ____ / ____ / ____

รองคณบดีฝ่ายวิชาการฯ

(นางสาวสุมาลี สมนึก)

วันที่ 4 / ๓ / ๖

คณบดี

(นางสาวละอองศรี เหนียงแจ่ม)

วันที่ 4 / กรกฎาคม 2566

<p>ผู้อำนวยการสถาบันวิจัยและพัฒนา (เลขานุการคณะกรรมการ)</p> <p>_____</p> <p>(_____)</p> <p>วันที่ ____ / ____ / ____</p>	<p>ผลการพิจารณาของอธิการบดี/ผู้รับมอบอำนาจ (ประธานคณะกรรมการ)</p> <p><input type="checkbox"/> อนุมัติ <input type="checkbox"/> ไม่อนุมัติ</p> <p>_____</p> <p>(_____)</p> <p>วันที่ ____ / ____ / ____</p>
--	--

- หลักฐานแนบ**
1. สำเนาหน้าปก และบทความที่ได้ตีพิมพ์และเผยแพร่ในการประชุม/วารสาร ฉบับสมบูรณ์
 2. Proceedings การประชุม (Hard Copy และ/หรือ CD)
 3. หลักฐานที่มีค่า ISI Impact Factor หรือ การจัดอยู่ในควอไทล์ (กรณีเป็นวารสาร)

หมายเหตุ 1. กรณีที่มีผู้วิจัยมากกว่า 1 คน ให้ผู้ที่ยื่นขอรับรางวัล นำรางวัลไปจัดสรรในกลุ่มผู้วิจัยเอง คณะกรรมการจะไม่รับผิดชอบกรณีการจัดสรรรางวัลในกลุ่มผู้วิจัย

หน้าปก



วารสารวิชาการ มทร. สุพรรณภูมิ

RMUTSB ACADEMIC JOURNAL

ปีที่ 11 ฉบับที่ 1 มกราคม - มิถุนายน 2566

ISSN 2651-1932 (Online)


บทความวิจัย

- ตัวประมาณค่าอัตราส่วนใหม่ สำหรับประมาณค่าเฉลี่ยประชากรภายใต้การสุ่มแบบชั้นภูมิและมีข้อมูลสูญหาย
ชูเกียรติ โพนแก้ว 1
- Factors affecting carsharing accessibility behavior in Bangkok
Saroch Boonsiripant and Tarid Songsang 17
- การจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่อง โดยการทำปัจจัยการคัดเลือกคุณลักษณะ
สายันห์ เทพแดง 29
- LIDAR for measuring growth of plant in smart farm
Benjapon Tubpeng et al. 45
- การศึกษาประสิทธิภาพของสารสกัดสีเขียวและไฮโดรโปนิกส์ในการฆ่าเชื้อจุลินทรีย์ในอาหารสำหรับเพาะเลี้ยงเนื้อเยื่อไม้น้ำบุษปฟาแลนดร้า
ชนากานต์ ลักษณะ: และคณะ 57
- ประสิทธิภาพของสารสกัดพอลิสปอร์เซีย *Colletotrichum* sp. สาเหตุโรคน้ำแฉกในสวงผลไม้-ม่วงอกร่อง
พิทูล นุชนวลรัตน์ และ นภาพร จิตต์ศรีธรา 67
- การศึกษาค้างของสารเคมีกำจัดศัตรูพืชในพืชสมุนไพร กรณีศึกษา: กลุ่มเกษตรกรผู้ปลูกพืชสมุนไพร บ้านดงบัง ตำบลดงหีหะสิ๊ก อำเภอเมืองปราจีนบุรี จังหวัดปราจีนบุรี
ณัฐฐา แสงนรินทร์ เหมจินดา และ ณัชชนก ประสิทธิ์พันธุ์ 79
- ผลของแผ่นครอบบังลมต่อการถ่ายเทความร้อนสู่ภายในของเตาแก๊ส KB-5 โดยพลศาสตร์ของไหลเชิงคำนวณ
มานะ วิชางาม และ พิศนพพงษ์ แก้วโพธิ์ 92
- การปรับปรุงฟังก์ชันงานของกระบวนการผลิตเครื่องครัวสแตนเลสด้วย CORELAP และวิธีการกราฟ
ชัยวัฒน์ กิตติศิธา และคณะ 110

บทความวิชาการ

- การศึกษามาตรฐานและสมรรถนะของเครื่องจำลองแสงอาทิตย์ชนิดไดโอดเปล่งแสง
นภัทร วัฒนเทพินทร์ และคณะ 123

Editorial statement



PDF (ภาษาไทย)

Published: Jun 27, 2023

Natthapong Wongdamnern
Rajamangaia University of Technology Suvarnabhumi

Abstract

วารสารวิชาการ มทร. สุวรรณภูมิ ปีที่ 11 ฉบับที่ 1 (มกราคม – มิถุนายน 2566) ฉบับนี้มีจำนวนบทความทั้งสิ้น 10 บทความ เป็นบทความวิจัย (Research Article) จำนวน 9 บทความ และบทความวิชาการ (Academic Article) จำนวน 1 บทความ ซึ่งทั้ง 10 บทความนี้ประกอบไปด้วยบทความด้านวิทยาศาสตร์และเทคโนโลยีคอมพิวเตอร์ เทคโนโลยีการเกษตร และวิศวกรรมศาสตร์ ทุกบทความเป็นบทความที่ทันสมัยเท่าทันความเป็นไปของโลกเทคโนโลยี และมีการบูรณาการหลายศาสตร์ เช่น บทความทางด้านคอมพิวเตอร์จะมีการใช้วิทยาการคำนวณ (Computational Science) ร่วมกับการเรียนรู้ของเครื่องมือ (Machine Learning) เพื่อสร้างแบบจำลองในการทำนายผลต่าง ๆ ที่น่าสนใจออกมา หรือทางด้านวิทยาศาสตร์และเทคโนโลยีจะมีการบูรณาการกับด้านเทคโนโลยีการเกษตร ตรวจสอบสารเคมีตกค้างในพืชชนิดต่างๆ หรือศึกษาผลของจุลินทรีย์ในผลิตภัณฑ์ทางการเกษตร ส่วนทางด้านวิศวกรรมศาสตร์จะเป็นการใช้หลักทางคณิตศาสตร์และที่ลึกลงในการคำนวณเพื่อออกแบบอุปกรณ์ ถึงอำนวยความสะดวกให้กับผู้ใช้ในชีวิตประจำวัน รวมไปถึงการออกแบบผังโรงงาน นอกจากนี้ยังมีบทความปริทัศน์ที่สรุปรวบรวมองค์ความรู้การออกแบบและสมรรถนะของเครื่องจำลองแลงเอาทิดยี่ห้อไดโอดเปล่งแสงเพื่อเป็นแนวทางในการนำไปใช้ประโยชน์

Journal Information



Approved by TCI during 2022 - 2024

Indexed in TCI

Editor : Dr.Natthapong Wongdamnern

Home ThaiJo

THAIJO

Manual

นโยบายการคุ้มครองข้อมูลส่วนบุคคล

การจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่อง โดยการหาปัจจัยการคัดเลือกคุณลักษณะ

The classification of diabetic patients using machine learning method by feature selection

สายัณห์ เทพแดง^{1*}

Sayan Tepdang^{1*}

บทคัดย่อ

การจำแนกผู้ป่วยโรคเบาหวาน เป็นเรื่องที่ยากในการจำแนกเนื่องจากไม่มีปัจจัยที่แน่นอนและต้องใช้หลากหลายปัจจัยในการวินิจฉัยโรคเบาหวาน บทความวิจัยนี้มีวัตถุประสงค์ในการจำแนกผู้ป่วยว่าเป็นโรคเบาหวาน หรือไม่โรคเบาหวาน ด้วยการใช้วิธีการเรียนรู้ด้วยเครื่อง (machine learning) โดยการหาปัจจัยการคัดเลือกคุณลักษณะ (feature selection) และได้ใช้ข้อมูลการจำแนกโรคเบาหวานจากเว็บไซต์ www.kaggle.com จำนวน 536 คน ซึ่งมีการเก็บข้อมูลทั้งหมด จำนวน 8 ปัจจัย ได้แก่ จำนวนครั้งที่ตั้งครรภ์ (pregnant), กลูโคสในเลือด (glucose), การวัดความดันโลหิต (blood pressure), ความหนาของผิวหนัง (skin thickness), ระดับอินซูลินในเลือด (insulin) และดัชนีมวลกาย (BMI) พันธุกรรมที่เป็นเปอร์เซ็นต์การเป็นโรคเบาหวาน (diabetes pedigree function) และอายุ (age) ในการเกิดโรคเบาหวาน โดยใช้การเรียนรู้และการทดสอบในอัตรา 90:10, 80:20, 70:30, 60:40, 50:50 เปอร์เซนต์ และใช้วิธีแบ่งข้อมูลแบบ 10-fold cross validation ผลการวิจัยพบว่าวิธีที่ดีที่สุดคือ gradient boosted trees มีประสิทธิภาพอยู่ที่ 87.14 เปอร์เซนต์ และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 0.80 และพบว่าวิธีการหาปัจจัยการคัดเลือกคุณลักษณะ ด้วยวิธีการคัดเลือกปัจจัยโดยใช้ค่าน้ำหนักของข้อมูล (filter approach) ตามวิธีโครงสร้างต้นไม้ (decision tree) ใช้ปัจจัยจำนวนเพียง 4 ปัจจัย ได้แก่ ระดับค่ากลูโคสในเลือด อายุ จำนวนครั้งที่ตั้งครรภ์ และสุดท้ายระดับค่าอินซูลิน ซึ่งถ้ามีการจำแนกผู้ป่วยโรคเบาหวานได้อย่างมีประสิทธิภาพ ก็สามารถรักษาได้อย่างรวดเร็ว และทำให้ผู้ป่วยโรคเบาหวานหายป่วยและมีอายุยืนยาวมากยิ่งขึ้น

คำสำคัญ: การจำแนกโรคเบาหวาน การเรียนรู้ด้วยเครื่อง การคัดเลือกคุณลักษณะ

Abstract

The classification of types of diabetic patients is difficult because there are not only variant features, but many features needed to diagnose the symptom of diabetes. This research proposes to classify the types of patients, whether or not they are diabetic, using machine learning to find the factor for feature selection. The study was utilized

¹ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

¹ Faculty of Business Administration and Information Technology, Rajamangala University of Technology Tawan-Ok

* Corresponding author. E-mail address: Sayan_te@rmutto.ac.th

Received: January 30, 2023; Revised: March 20, 2023; Accepted: April 10, 2023

data of 536 people from the website <https://www.kaggle.com>, that collected on 8 features causing diabetes as following: Pregnancies, glucose in blood, blood pressure, skin thickness, insulin in blood, body mass index, diabetes pedigree function, and age. By training and testing ratio of 90:10%, 80:20%, 70:30%, 60:40%, 50:50% and splitting a data set for 10-fold cross-validation, the result was showed that the optimizing method, Gradient Boosted Trees, has an efficiency at 87.14% and standard deviation at 0.80 with the best efficacy of feature selection by Filter-based factor selection method with Decision Tree of only 4 factors: glucose in blood, age, frequency of pregnancies and insulin in blood. According those of factors, the efficacy of diabetic classification would heal and cure diabetic with a speedy recovery and longer life.

Keywords: the classification of diabetic, machine learning, feature selection

บทนำ

โรคเบาหวาน (diabetes mellitus: DM) เป็นภาวะที่ร่างกายมีน้ำตาล (กลูโคส) ในเลือดสูงกว่าปกติ เนื่องจากการขาดฮอร์โมนอินซูลิน (insulin) ที่สร้างมาจากตับอ่อนไม่สามารถทำหน้าที่ในการนำน้ำตาลในเลือดเข้าไปในเซลล์ต่าง ๆ ของร่างกาย เพื่อนำไปใช้เป็นพลังงาน หากปล่อยให้ร่างกายอยู่ในสภาวะนี้เป็นเวลานานจะทำให้ก่อโรคต่าง ๆ เสื่อม เกิดโรคและอาการแทรกซ้อนขึ้น (Thatoom Hospital, 2014) โดยสถานการณ์โรคเบาหวานทั่วโลกในปี 2022 มีผู้ป่วยจำนวน 537 ล้านคน และคาดว่าในปี 2030 จะมีผู้ป่วยเบาหวานเพิ่มขึ้นเป็น 643 ล้านคน และโรคเบาหวานมีส่วนทำให้เสียชีวิต สูงถึง 6.70 ล้านคน หรือเสียชีวิต 1 ราย ในทุก ๆ 5 วินาที จากรายงานสถิติสาธารณสุข กระทรวงสาธารณสุขในส่วนของประเทศไทยพบอุบัติการณ์โรคเบาหวานมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง มีผู้ป่วยรายใหม่เพิ่มขึ้น 3 แสนคนต่อปี และมีผู้ป่วยโรคเบาหวานอยู่ในระบบทะเบียน 3.30 ล้านคน ในปี 2021 มีผู้เสียชีวิตจากโรคเบาหวานทั้งหมด 16,388 คน (อัตราตาย 25.1 ต่อประชากรแสนคน) ค่าใช้จ่ายด้านสาธารณสุขในการรักษา

โรคเบาหวานเฉลี่ยสูงถึง 47,596 ล้านบาทต่อปี นอกจากนี้โรคเบาหวานยังคงเป็นสาเหตุหลักที่ก่อให้เกิดโรคอื่น ๆ ในกลุ่มโรค NCDs เช่น โรคหัวใจ โรคหลอดเลือดสมอง โรคความดันโลหิตสูง และโรคไตวายเรื้อรัง (Bureau of Information Office of the Permanent Secretary, 2020)

สาเหตุของการเป็นโรคเบาหวานมีหลายปัจจัยร่วมกัน เช่น อายุ การตั้งครรภ์ ความอ้วน ความเครียดเรื้อรัง และการได้รับยาบางชนิด เป็นต้น ในส่วนคนที่มีความเสี่ยงโรคเบาหวานมีหลายปัจจัย เช่น อายุมากกว่า 45 ปีขึ้นไป มีประวัติคนในครอบครัวเป็นโรคเบาหวาน เป็นผู้มีน้ำหนักเกินหรือมีดัชนีมวลกายที่สูง ความดันโลหิตสูง (ความดันโลหิตตั้งแต่ 140/90 มิลลิเมตรปรอท) ไม่ออกกำลังกาย ดื่มสุรา สูบบุหรี่ และเคยตรวจพบระดับน้ำตาลสะสมมากกว่าหรือเท่ากับ 5.70 เปอร์เซ็นต์ เป็นต้น โดยภาวะก่อนเป็นเบาหวาน (impaired fasting glucose) จะมีระดับน้ำตาลในกระแสเลือดระหว่าง 100-125 มิลลิกรัมต่อเดซิลิตร ไชมันชนิดชนิดเอชดีแอล (HDL) น้อยกว่า 35 มิลลิกรัมต่อเดซิลิตร หรือไตรกลีเซอไรด์ (TG) มากกว่า 250 มิลลิกรัมต่อเดซิลิตร เป็นต้น (Phuket Hospital, 2022)

ในส่วนของงานวิจัยในปัจจุบันได้นำวิธีการปัญญาประดิษฐ์ (artificial intelligence: AI) มาใช้ในการวิจัย โดยพบว่าการเรียนรู้ด้วยเครื่อง (machine learning) เป็นส่วนหนึ่งของปัญญาประดิษฐ์ การเรียนรู้ด้วยเครื่องสามารถแบ่งได้ 3 ประเภทหลัก คือ supervised learning เป็นการสอนให้เรียนรู้จากการแบ่งชุดข้อมูล การระบุ input และ output ไว้อย่างชัดเจน เพื่อสร้างโมเดลต่าง ๆ เป็นต้น ในส่วนของ unsupervised learning เป็นการสอนให้เรียนรู้จากชุดข้อมูลที่ไม่มีการแบ่งกลุ่ม หรือระบุความสัมพันธ์ของข้อมูลไว้ชัดเจน และสุดท้าย reinforcement learning เป็นการสอนให้เรียนรู้จากการทดลองและพยายามค้นหาคำตอบของปัญหา เพื่อให้ได้คำตอบที่มีประสิทธิภาพที่ดีที่สุด

ในส่วนการนำวิธีการเรียนรู้ด้วยเครื่องไปใช้ในงานวิจัยในด้านต่าง ๆ เช่น ด้านภาษาศาสตร์ (linguistics) โดยได้นำมาใช้ในการประมวลผลภาษาธรรมชาติ (natural language processing) คือ การทำให้คอมพิวเตอร์สามารถเข้าใจภาษามนุษย์มากขึ้น เช่น การนำไปวิเคราะห์ข้อมูลทางการแปลภาษา ข้อความ และความรู้สึกต่าง ๆ ในโซเชียลมีเดีย เป็นต้น ในส่วนของงานวิจัยที่นำไปใช้ในด้านวิศวกรรมศาสตร์ (engineering) ได้นำไปใช้ในหาค้นหาองค์ความรู้ต่าง ๆ เช่น การสร้างหุ่นยนต์ การวิเคราะห์ข้อมูลขนาดใหญ่ (big data) หรือจะเป็นลักษณะงานที่เป็น internet of things (IoT) ที่สามารถตอบสนองความต้องการของผู้ใช้งานได้ เป็นต้น และในส่วนของงานวิจัยที่นำไปใช้ทางด้านการแพทย์ หรือวิทยาศาสตร์สุขภาพ ได้นำไปใช้ในการประมวลผลภาพทางการแพทย์ (medical image processing) เช่น การนำภาพ MRI มาไปจำแนกการเกิดโรคต่าง ๆ และยังสามารถนำไปใช้ในการ

พยากรณ์อาการของผู้ป่วย ตลอดจนการวินิจฉัยโรคต่าง ๆ ได้อย่างถูกต้อง และแม่นยำมากขึ้น นอกจากนี้สามารถนำวิธีการเรียนรู้ด้วยเครื่องไปใช้ในงานวิจัยทางด้านอื่น ๆ ในหลากหลายด้านได้อีกด้วย

งานวิจัยที่เกี่ยวข้องกับการจำแนกผู้ป่วยโรคเบาหวานแบ่งได้สองประเภท ได้แก่ การเรียนรู้ด้วยเครื่องเพียงอย่างเดียว และการเรียนรู้ด้วยเครื่องโดยการหาปัจจัยการคัดเลือกคุณลักษณะ (feature selection)

ในส่วนของงานวิจัยประเภทแรกการเรียนรู้ด้วยเครื่องเพียงอย่างเดียว คือ การเรียนรู้ด้วยเครื่องในการจำแนกตามที่ได้กำหนดไว้โดยจะให้คำตอบเป็น label / class เท่านั้น งานวิจัยในกลุ่มนี้ เช่น การจำแนกประเภทโรคเบาหวานด้วยการเรียนรู้ของเครื่องและการคาดการณ์สำหรับการใช้งานด้านการดูแลสุขภาพ (Butt et al., 2021) การสำรวจเครื่องจักรอย่างครอบคลุมการเรียนรู้เทคนิคการตรวจหาโรคเบาหวาน (Sidong, Xuejiao, & Chunyan, 2018) การจำแนกประเภทของโรคเบาหวานโดยใช้ซอฟต์แวร์คอมพิวเตอร์และการเรียนรู้ด้วยเครื่อง (Saxena, Sharma, Gupta, & Sampada, 2022) และระบบการจำแนกผู้ป่วยเบาหวานด้วยเทคนิคการเรียนรู้ของเครื่อง (Rawat, & Suryakant, 2019) จากงานวิจัยประเภทแรกพบว่ามีการใช้วิธีการเรียนรู้ด้วยเครื่องในการจำแนกหลายวิธี เช่น logit boost, Naive Bayes, deep learning, logistic regression และ support vector machine (SVM) เป็นต้น ซึ่งพบว่าข้อดีของงานวิจัยประเภทนี้ คือสามารถทำการวิจัยได้อย่างรวดเร็ว แต่ก็พบว่าประสิทธิภาพที่อาจจะไม่ได้ดีที่สุด

ในส่วนงานวิจัยประเภทที่สอง คือ การเรียนรู้ด้วยเครื่องโดยการหาปัจจัยการคัดเลือกคุณลักษณะเป็นการจำแนกตามที่ได้กำหนดไว้โดยจะให้คำตอบเป็น label / class เช่นกัน แต่จะพบว่ามีการหาปัจจัยการคัดเลือกคุณลักษณะด้วย ตัวอย่างเช่น ปัจจัย (feature) ที่มีจำนวนมากในการจำแนกประเภท ข้อความทัศนคติ (sentiment) ออกเป็นเชิงบวก (positive) หรือเชิงลบ (negative) นั้นจะมีคำในข้อความต่าง ๆ ที่ใช้เป็นปัจจัยจำนวนมาก ปัจจัยเหล่านี้บางอันก็ไม่ได้มีความสำคัญในการแบ่งแยกคลาส (class) ออกเป็นเชิงบวกหรือเชิงลบได้ ดังนั้น จึงจำเป็นต้องทำการคัดเลือกปัจจัยที่สำคัญหรือมีน้ำหนักมากที่สุดมาใช้งาน ขั้นตอนนี้เรียกว่าการคัดเลือกปัจจัย หรือ feature selection ซึ่งสามารถแบ่งได้เป็น 2 กลุ่มใหญ่ดังนี้ ได้แก่

filter approach เป็นการหาปัจจัยการคัดเลือกคุณลักษณะโดยใช้วิธีการคำนวณหาค่าน้ำหนักซึ่งอาจจะเป็นค่าความสัมพันธ์ระหว่างแต่ละปัจจัยในและคลาสต่าง ๆ แล้วจะเลือกปัจจัยที่มีค่าน้ำหนัก เช่น การหาค่าสหสัมพันธ์ (correlation coefficient) และ การหาค่าน้ำหนักตามโครงสร้างต้นไม้ (decision tree) เป็นต้น

wrapper approach เป็นการคัดเลือกปัจจัยด้วยการสร้างโมเดล (classification model) ขึ้นมาจากเซตของปัจจัยที่กำหนดไว้และวัดประสิทธิภาพการทำงานของโมเดล และเลือกเซตของปัจจัยที่ทำให้โมเดลมีประสิทธิภาพมากที่สุดมาใช้งาน เช่น โมเดลที่ให้ค่าความถูกต้อง (accuracy) มากที่สุด โดยการคัดเลือกปัจจัยด้วยวิธีการนี้แบ่งย่อยได้เป็น 2 แบบใหญ่ ๆ คือ forward selection เป็นการสร้างโมเดลโดยการเพิ่มปัจจัยทีละ 1 ปัจจัย ถ้าปัจจัยที่ใส่เพิ่มทำให้ประสิทธิภาพที่ดี ก็จะถูกเก็บไว้และเลือกปัจจัยอื่น ๆ

มาเพิ่มต่อไปจนประสิทธิภาพของโมเดลไม่ได้ดีขึ้นก็จะหยุดทำงาน ในส่วนของ backward elimination เป็นการสร้างโมเดลที่เริ่มจากการใช้ปัจจัยทั้งหมดก่อนและตัด (eliminate) ปัจจัยที่ไม่สำคัญทิ้งไปทีละปัจจัยถ้าประสิทธิภาพดีขึ้นก็ตัดปัจจัยอื่น ๆ ต่อไป (Th.Linkedin, 2023)

งานวิจัยประเภทที่สอง การเรียนรู้ด้วยเครื่องโดยการหาปัจจัยการคัดเลือกคุณลักษณะ เช่น การจำแนกข้อมูลเพื่อวินิจฉัยความเสี่ยงการเป็นโรคเบาหวานโดยใช้เทคนิควิธีแบบร่วมกันตัดสินใจและวิธีเลือกคุณลักษณะเด่นไปข้างหน้า (Nonsiri, Chaichitwanichakol, & Somkantha, 2022) แนวทางใหม่สำหรับการเลือกคุณลักษณะและการจำแนกประเภทโรคเบาหวานวิธีการเรียนรู้ของเครื่อง (Saxena, Sharma, Gupta, & Sampada, 2022) และการเลือกคุณสมบัติที่สำคัญและการเปรียบเทียบความแม่นยำที่แตกต่างกัน โมเดลการเรียนรู้ด้วยเครื่องสำหรับการตรวจหาเบาหวานในระยะเริ่มต้น (Rubaiat, Rahman, & Hasan, 2018) ซึ่งพบว่าข้อดีของงานวิจัยในกลุ่มนี้ คือ มีการหาปัจจัยที่มีประสิทธิภาพมากที่สุด แต่อาจจะใช้เวลาในการหาปัจจัยที่ดีที่สุด

จากงานวิจัยส่วนใหญ่พบว่าการจำแนกผู้ป่วยโรคเบาหวาน เป็นไปในลักษณะการเรียนรู้ด้วยเครื่องเพียงอย่างเดียว เนื่องจากสามารถทำได้รวดเร็วและไม่มีความซับซ้อน โดยพบว่าข้อจำกัดของประเภทนี้คือ ผลที่ได้อาจจะมียุทธศาสตร์ที่ไม่ดีที่สุด เพราะไม่ได้หาปัจจัยที่สำคัญในการเรียนรู้ ตัวอย่างเช่น ถ้ามีคุณสมบัติหรือปัจจัยจำนวนมากในการเรียนรู้จะทำให้เกิดการเรียนรู้ที่มากขึ้น ซึ่งพบว่าบางปัจจัยอาจจะไม่สำคัญและทำให้เกิดความปัญหาในการจำแนกและทำให้ผลประสิทธิภาพ

ลดลงได้ เป็นต้น จากข้อจำกัดดังกล่าวจากการเรียนรู้ด้วยเครื่องเพียงอย่างเดียว ผู้วิจัยได้มีวัตถุประสงค์การจำแนกผู้ป่วยว่าเป็นโรคเบาหวานหรือไม่เป็นโรคเบาหวาน ด้วยการใช้วิธีการเรียนรู้ด้วยเครื่อง โดยการหาปัจจัยการคัดเลือกคุณลักษณะเพื่อสามารถหาผลการวิจัยที่มีประสิทธิภาพที่สุดและลดจำนวนปัจจัยจำนวนมากในการเรียนรู้ด้วยเครื่อง โดยการใช้การเรียนรู้ด้วยเครื่องได้ใช้วิธี แบบ supervised learning เป็นการสอนให้เรียนรู้จากการแบ่งชุดข้อมูลการระบุ input และ output ไว้ เพื่อสร้างโมเดลต่าง ๆ โดยจะใช้ 5 วิธี ได้แก่ การเรียนรู้โดยใช้หลักการความน่าจะเป็น (Naive Bayes) การเรียนรู้แบบ binary classification (logistic regression) การเรียนรู้ด้วยเครื่องแบบโครงข่ายประสาท (deep learning) การเรียนรู้แบบโครงสร้างต้นไม้ (gradient boosted trees) และสุดท้ายการเรียนรู้ด้วยเครื่องโดยการหาสัมประสิทธิ์ของสมการ (support vector machine) เนื่องจากแต่ละวิธีของการเรียนรู้ด้วยเครื่องมีข้อดีข้อเสียแตกต่างกัน และพบว่าทั้ง 5 วิธีการนี้ได้นำไปใช้ในงานวิจัยด้านต่าง ๆ ในการจำแนกและพบว่าได้ผลดีมีประสิทธิภาพในงานวิจัย ดังนั้นจึงได้นำไปใช้ในการจำแนกผู้ป่วยโรคเบาหวานต่อไป ในส่วนของการหาปัจจัยการคัดเลือกคุณลักษณะ จะใช้วิธีการหาค่าน้ำหนักตามโครงสร้างต้นไม้ การวิจัยจึงเป็นเรื่องที่น่าสนใจและสามารถหาปัจจัยที่สำคัญในการจำแนกโรคเบาหวานได้อย่างมีประสิทธิภาพมากกว่าการเรียนรู้ด้วยเครื่องเพียงอย่างเดียว

วิธีการศึกษา

วิธีการดำเนินการวิจัย จะทำจากการศึกษาวิธีการและทฤษฎีต่าง ๆ ที่เกี่ยวข้องกับการจำแนก

ผู้ป่วยว่าเป็นโรคเบาหวาน หรือไม่เป็นโรคเบาหวาน จะประกอบไปด้วย 5 ขั้นตอน ได้แก่ dataset (ข้อมูล) data preparation (การเตรียมข้อมูล) feature selection (การหาปัจจัยการคัดเลือกคุณลักษณะ) classification (การจำแนก) และสุดท้าย (result) ผลการทดลอง ดัง (Figure 1)

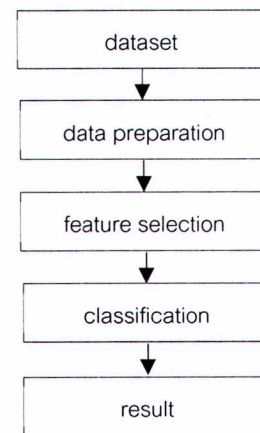


Figure 1 The research process.

ข้อมูล (dataset) คือ ข้อมูลที่มีการรวบรวมเป็นทุติยภูมิ (secondary data) ซึ่งพบว่ามีการดาวน์โหลดข้อมูลจำนวน 33,667 ครั้ง ในระยะเวลา 6 เดือนที่ผ่านมา โดยข้อมูลนำมาจากสถาบันโรคเบาหวานและระบบทางเดินอาหารและโรคไตแห่งชาติของประเทศอินเดีย โดยเฉพาะอย่างยิ่งการเก็บข้อมูลจะเป็นผู้หญิงทั้งหมดมีอายุไม่ต่ำกว่า 21 ปี มีการนำใช้ จำนวน 536 คน ข้อมูลโดยแบ่งเป็นคนที่เป็นโรคเบาหวาน จำนวน 268 คน และคนที่ไม่เป็นโรคเบาหวาน จำนวน 268 คน มีการจัดเก็บปัจจัยในการเกิดโรคมีย 8 ปัจจัย ซึ่งข้อมูลมาจากเว็บไซต์ www.kaggle.com (Dataset, 2023) ดัง (Figure 2)

จาก (Figure 2) ตัวอย่างข้อมูลเป็นใน รูปของ CSV ไฟล์ โดยจะอธิบายการเก็บข้อมูล ลักษณะแถว (row) และ คอลัมน์ (column) และอยู่ใน ดัง (Table 1)

Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
6	148	72	35	0	33.6	0.627	50	1
1	85	66	29	0	26.6	0.351	31	0
8	183	64	0	0	23.3	0.672	32	1
1	89	66	23	94	28.1	0.167	21	0
0	137	40	35	168	43.1	2.288	33	1
5	116	74	0	0	25.6	0.201	30	0
3	78	50	32	88	31	0.248	26	1
10	115	0	0	0	35.3	0.134	29	0
2	197	70	45	543	30.5	0.158	53	1
8	125	96	0	0	0	0.232	54	1
4	110	92	0	0	37.6	0.191	30	0
10	168	74	0	0	38	0.537	34	1
10	139	80	0	0	27.1	1.441	57	0
1	189	60	23	846	30.1	0.398	59	1
5	166	72	19	175	25.8	0.587	51	1
7	100	0	0	0	30	0.484	32	1
0	118	84	47	230	45.8	0.551	31	1

Figure 2 The sample of the diabetes dataset.

Table 1 The detail of data structure.

features	detail
pregnancies	the frequency of pregnancies
glucose	the glucose level in blood
blood pressure	the blood pressure measurement
skin thickness	the thickness of the skin
insulin	the insulin level in blood
BMI	the body mass index
diabetes pedigree function	the diabetes percentage
age	the age
outcome	the final result 1 is yes and 0 is no

การเตรียมข้อมูล (data preparation) จัดเตรียมข้อมูลให้อยู่ในรูปแบบเพื่อนำไปทำการ train และ test โดยจะข้อมูลที่เป็นแบบ 10-fold cross validation

การหาปัจจัยการคัดเลือกคุณลักษณะ (feature selection) ในส่วนการหาปัจจัยการคัดเลือก

คุณลักษณะเป็นแบบ filter approach เป็นการคัดเลือกปัจจัยจะใช้โดยการค่าน้ำหนักของข้อมูล ซึ่งจะใช้แบบ decision tree เป็นการหาน้ำหนักของโครงสร้างต้นไม้การตัดสินใจจากบนลงล่าง ดังสูตร (1) และ สูตร (2) การหาค่าน้ำหนักของต้นไม้

ลักษณะเรียกว่าเกนความรู้ (information gain) ตาม โดยนิยามเอนโทรปีของต้นไม้การตัดสินใจในตัว
 สูตรที่ (2) จะต้องนิยามค่าหนึ่งที่ใช้บอกความไม่ ในเซตของตัวอย่าง S คือ E(S) ตามสูตร (1) ตาม
 บริสุทธิ์ของข้อมูลก่อน เรียกว่าเอนโทรปี (entropy) ด้านล่าง (Th.wikipedia, 2021)

$$E(s) = - \sum_{j=1}^n ps(j) \log_2 Ps(j) \tag{1}$$

s คือ ตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลาย ๆ กรณี
 Ps(j) คือ อัตราส่วนของกรณีใน S ที่ตัวแปรตามหรือผลลัพธ์มีค่า j
 ในส่วนของการหาค่า (information gain) และสูตร (2)

$$Gain(S, A) = E(s) - \sum_{v=value(A)} \frac{|sv|}{|s|} E(S_v) \tag{2}$$

s คือ ตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลาย ๆ กรณี
 E คือ เอนโทรปีของตัวอย่าง A คือ ตัวแปรต้นที่พิจารณา
 value(A) คือ เซตของค่าของ A ที่เป็นไปได้ S_v คือ ตัวอย่างที่ A มีค่า v ทั้งหมด

หลังจากนั้นเมื่อได้ค่าต่าง ๆ และได้ค่าน้ำหนัก
 ของข้อมูลที่มาจากการหาโดย decision tree ซึ่งเป็น
 การ filter approach โดยการหาปัจจัยการคัดเลือก
 คุณลักษณะโดยใช้วิธีการคำนวณหาค่าน้ำหนัก
 หลังจากนั้นนำไปใช้ในส่วนของการหาปัจจัยแบบ
 wrapper approach เป็นการคัดเลือกปัจจัยในการ
 สร้างโมเดลเป็นแบบ backward elimination โดยการ
 ใช้ค่าน้ำหนักที่หาได้นำใช้ในการตัดปัจจัยที่ไม่สำคัญ
 ออกไป

การจำแนก (classification) การจำแนก
 โรคเบาหวาน จากข้อมูลพบว่ามีความหลากหลาย เช่น
 เป็นจำนวนเต็ม เป็นจุดทศนิยม และมีหลากหลาย
 ปัจจัยในการเก็บข้อมูล และงานวิจัยก่อนหน้านี้ได้ใช้
 วิธีการจำแนกหลายวิธี เช่น Naïve Bayes, gradient
 boosted trees, deep learning, logistic regression

และ support vector machine (SVM) พบว่ามีประสิทธิภาพ
 ในการจำแนกและได้ผลดีแตกต่างกัน ประกอบกับ
 ผู้วิจัยต้องการวิธีการเรียนรู้ด้วยเครื่องในการจำแนกที่
 แตกต่างกันด้วย ดังนั้นจึงได้ใช้ 5 วิธีในการวิเคราะห์
 ข้อมูลและจำแนกข้อมูลและใช้สูตรที่ 3 ในการประเมิน
 ประสิทธิภาพของโมเดล ซึ่งได้แก่ 1) Naïve Bayes
 เป็นเรื่องใช้หลักการของเรื่องความน่าจะเป็น (probability)
 ในการจำแนกแบ่งกลุ่ม (Medium, 2023) 2) logistic
 regression เป็นเทคนิคการจำแนกโดยอาศัยหลักการ
 ความน่าจะเป็นในการเกิดเหตุการณ์หรือไม่เกิด
 เหตุการณ์นั้น ซึ่งสามารถจัดอยู่ในประเภท binary
 classification ตัวอย่างการใช้งาน logistic regression
 ส่วนใหญ่นำไปใช้ในการจำแนกโอกาสในการเกิดโรค
 หรือไม่เกิดโรค (Kasetsart University, 2018) 3) deep
 learning คือวิธีการเรียนรู้ด้วยเครื่องแบบโครงข่าย

ประสาท โดยนำระบบโครงข่ายประสาท (neural network) มาซ้อนกันหลายชั้น (layer) และทำการเรียนรู้จากข้อมูลในการจำแนก (ABB, 2023) 4) gradient boosted trees คือโครงสร้างแบบต้นไม้ จะทำการประเมินผลแต่ละจำลอง ให้มีค่าประสิทธิภาพที่ดีที่สุด โดยการพยายามให้ classifier instance ที่มาใหม่แต่ละตัว มีความแม่นยำขึ้นเรื่อย ๆ โดยเรียนรู้จากค่าความคลาดเคลื่อนสะสมที่เกิดจากการจำแนกก่อนหน้า (Dhurakij Pundit University, 2023) 5) support vector machine (SVM) เป็นอัลกอริทึมที่สามารถนำมาช่วยแก้ปัญหาการจำแนกข้อมูล โดยอาศัยหลักการของการหาสมมติฐานของสมการเพื่อสร้างเส้นแบ่งแยกกลุ่มข้อมูลที่ถูกป้อนเข้าสู่กระบวนการสอนให้ระบบเรียนรู้ โดยเน้นไปยังเส้นแบ่งแยกและกลุ่มข้อมูล (Glurgeek, 2023)

ในส่วนของโปรแกรมที่นำมาใช้ในการประมวลผลคือ โปรแกรม rapidminer โดยเลือกการตั้งค่าวิธีต่าง ๆ เป็นแบบ optimization เพื่อให้ค่าที่เหมาะสมที่สุดในการประมวลผล

ผลการศึกษา

การดำเนินการวิจัยในขั้นตอนแรกใช้วิธีการเรียนรู้ด้วยเครื่องจะใช้ปัจจัยทั้งหมดก่อน ซึ่งใช้จำนวน 8 ปัจจัยในการจำแนกโรคเบาหวาน ได้แก่ จำนวนการตั้งครรภ์ (pregnancies) ระดับกลูโคสในเลือด การวัดความดันโลหิต (blood pressure) ความหนาของผิวหนัง (skin thickness) ระดับอินซูลินในเลือด (insulin) ดัชนีมวลกาย (BMI) พันธุกรรมที่เป็นเปอร์เซ็นต์การเป็นโรคเบาหวาน (diabetes pedigree function) อายุ (age) ซึ่งจะใช้จำนวนเรียนรู้และการทดสอบใน อัตรา 90:10 เปอร์เซนต์ และใช้วิธีแบบ 10-fold cross validation

โดยสูตรในการประเมินประสิทธิภาพ ตามสูตร (3) และผลการทดลอง ดัง (Table 2) โดยผลการวิจัยจาก 8 ปัจจัยทั้งหมดในการจำแนกโรคเบาหวาน

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{FP} + \text{TP} + \text{FN}} \quad (3)$$

ผลบวกจริง (true positive) ผู้ป่วยตรวจพบว่า มีโรคอย่างถูกต้อง

ผลบวกปลอม (false positive) คนปกติตรวจพบว่า มีโรคอย่างไม่ต้อง

ผลลบจริง (true negative) คนปกติตรวจพบว่า ไม่มีโรคอย่างถูกต้อง

ผลลบปลอม (false negative) คนป่วยตรวจพบว่า ไม่มีโรคอย่างไม่ต้อง

จาก (Table 2) ผลการวิจัยจากปัจจัยทั้งหมด 8 ปัจจัยในการจำแนกโรคเบาหวาน พบว่า gradient boosted trees มีประสิทธิภาพดีที่สุด (Acc) อยู่ที่ 86.79 เปอร์เซนต์ และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 0.98 หลังจากนั้นจะทำการหาปัจจัยการคัดเลือกคุณลักษณะ (feature selection) ซึ่งจะเป็นวิธีการ filter approach โดยผลการคำนวณหาค่าน้ำหนักตาม decision tree มีผลดัง (Table 3)

เมื่อสร้างโมเดลที่เริ่มจากการใช้ปัจจัยทั้งหมดจำนวน 8 ปัจจัยแล้ว จาก (Table 3) การหาค่าน้ำหนักตามโครงสร้างของต้นไม้ decision tree โดยเรียงน้ำหนักที่มากที่สุดตามลำดับบนลงล่าง และใช้ค่าน้ำหนักจาก (Table 3) ไปหา feature selection ซึ่งจะได้จำนวน 7 ปัจจัย, 6 ปัจจัย และลดลงเรื่อยจนถึง 3 ปัจจัยตามลำดับ ซึ่งแสดงจำนวนปัจจัย ดัง (Table 4-5) เป็นผลการจำแนกจากการหา feature selection

Table 2 The result of all features.

classification	accuracy (Acc)	standard deviation (SD)
Naïve Bayes	77.14	10.05
logistic regression	82.14	11.01
deep learning	76.79	9.62
gradient boosted trees	86.79	0.98
support vector machine	80.00	11.18

Table 3 The feature selection for weight the decision tree.

feature selection	decision tree
glucose	0.33
age	0.11
pregnancies	0.07
insulin	0.05
diabetes pedigree function	0.05
skin thickness	0.04
BMI	0.02
blood pressure	0.01

Table 4 The result of finding the feature selection.

number of features	feature selection	it cannot be used because minimum weight (Table 3)
7	- glucose - age - pregnancies - insulin - diabetes pedigree function - skin thickness - BMI	- blood pressure

Table 4 The result of finding the feature selection (continue).

number of features	feature selection	it cannot be used because minimum weight (Table 3)
6	<ul style="list-style-type: none"> - glucose - age - pregnancies - insulin - diabetes pedigree function - skin thickness 	<ul style="list-style-type: none"> - blood pressure - BMI
5	<ul style="list-style-type: none"> - glucose - age - pregnancies - insulin - diabetes pedigree function 	<ul style="list-style-type: none"> - blood pressure - BMI - skin thickness
4	<ul style="list-style-type: none"> - glucose - age - pregnancies - insulin 	<ul style="list-style-type: none"> - blood pressure - BMI - skin thickness - diabetes pedigree function
3	<ul style="list-style-type: none"> - glucose - age - pregnancies 	<ul style="list-style-type: none"> - blood pressure - BMI - skin thickness - diabetes pedigree function

Table 5 The result of finding the classification by feature selection.

feature selection	Naïve Bayes		logistic regression		deep learning		gradient boosted trees		SVM	
	Acc	SD	Acc	SD	Acc	SD	Acc	SD	Acc	SD
7	77.14	10.05	82.14	11.01	79.29	10.61	81.79	6.24	82.14	6.56
6	82.14	6.56	81.79	6.24	82.14	6.56	84.29	5.27	81.79	6.24
5	82.14	6.56	84.29	5.27	84.64	13.63	86.79	0.98	84.29	5.27
4	82.14	6.56	84.29	5.27	81.79	6.24	87.14	0.80	76.79	6.19
3	77.14	10.05	74.29	1.60	82.14	11.01	84.64	5.45	80.00	6.85

จาก (Table 5) ผลการวิจัยพบว่าประสิทธิภาพ (Acc) มีค่าสูงสุดคือ gradient boosted trees อยู่ที่ 87.14 เปอร์เซ็นต์ และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 0.80 ในส่วนการหาปัจจัย (feature selection) ตามค่าน้ำหนักตามโครงสร้างของต้นไม้ decision tree พบว่าการใช้ปัจจัย 4 ปัจจัย ได้แก่ ระดับกลูโคส ในเลือด (glucose) อายุ (age) จำนวนการตั้งครรภ์ (pregnancies) ระดับอินซูลินในเลือด (insulin) หลังจากนั้นก็นำไปดำเนินการวิจัยในรูปแบบข้อมูลเพื่อการเรียนรู้และการทดสอบในขนาด 90:10 เปอร์เซ็นต์, 80:20 เปอร์เซ็นต์, 70:30 เปอร์เซ็นต์, 60:40 เปอร์เซ็นต์ และ 50:50 เปอร์เซ็นต์ ดัง (Table 6)

Table 6 The result of the classification training: test.

train: test	Naïve Bayes		logistic regression		deep Learning		gradient boosted trees		SVM	
	Acc	SD	Acc	SD	Acc	SD	Acc	SD	Acc	SD
90:10%	82.14	6.56	84.29	5.27	81.79	6.24	87.14	0.80	76.79	6.19
80:20%	72.67	5.61	75.00	2.89	72.33	3.25	77.92	3.51	70.17	3.01
70:30%	73.72	5.99	77.19	1.88	73.04	3.64	76.32	2.24	71.90	2.80
60:40%	76.37	6.05	74.04	3.05	77.31	5.89	76.49	2.44	71.20	5.55
50:50%	68.57	4.29	71.20	2.65	71.20	2.65	71.71	3.55	60.73	3.25

จาก (Table 6) พบว่าวิธีการที่ดีที่สุดในระดับขนาดการเรียนรู้และการทดสอบ 90:10 เปอร์เซ็นต์ คือ gradient boosted trees มีค่าประสิทธิภาพ (Acc) อยู่ที่ 87.14 และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 0.80 และขนาดการเรียนรู้และการทดสอบ 80:20 เปอร์เซ็นต์ คือ gradient boosted trees มีค่าประสิทธิภาพ (Acc) อยู่ที่ 77.92 และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 3.51 ซึ่งเป็นวิธีการที่ดีที่สุด

รองลงมาคือ logistic regression ขนาดการเรียนรู้ และการทดสอบ 90:10 เปอร์เซนต์ มีค่าประสิทธิภาพ (Acc) อยู่ที่ 84.29 และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 5.27 และขนาดการเรียนรู้และการทดสอบ

80:20 เปอร์เซนต์ อยู่ที่ logistic regression มีค่าประสิทธิภาพ (Acc) อยู่ที่ 75.00 และค่าเบี่ยงเบนมาตรฐาน (SD) อยู่ที่ 2.89 เป็นต้น และสุดท้ายเป็น (Table 7) การจำแนกผิดพลาด

Table 7 The errors in classification.

number	glucose	age	pregnancies	insulin	result (0)	result (1)	result for system	real
1	123	22	3	240	0.41	0.59	1	0
2	127	51	11	0	0.20	0.80	1	0
3	100	46	14	184	0.53	0.47	0	1
4	102	36	6	0	0.64	0.36	0	1

จาก (Table 7) การจำแนกการผิดพลาด พบว่า เกิดปัจจัยค่าน้ำหนักของโครงสร้างแบบต้นไม้ ดัง (Table 3) พบว่า ระดับกลูโคสในเลือด อยู่ที่ 0.33 อายุ อยู่ที่ 0.11 จำนวนการตั้งครรภ์ อยู่ที่ 0.07 ระดับอินซูลิน ในเลือด อยู่ที่ 0.05 จึงพบว่ามีรายการการผิดพลาดดังนี้

รายการที่ 1 มีการจำแนกผิดพลาด ซึ่งจากการ จำแนกบอกว่า ไม่เป็นโรคเบาหวาน (result (0)) อยู่ที่ 0.41 เปอร์เซนต์ และบอกว่า เป็นโรคเบาหวาน (result (1)) อยู่ที่ 0.59 เปอร์เซนต์ ผลการจำแนกจากระบบ result for system บอกว่าเป็นโรคเบาหวาน (1) แต่ผลที่ถูกต้อง (real) คือ ไม่เป็นโรคเบาหวาน (0) ในส่วนที่มีผลทำให้เกิด ความผิดพลาดในการจำแนก คือ มีระดับกลูโคสในเลือด 123 อยู่ในระดับเกือบสูง (ไม่ควรเกิน 125 มิลลิกรัมต่อ เดซิลิตร) ระดับค่าอินซูลินในเลือด 240 อยู่ในระดับสูง แต่อายุเพียง 22 ปี ทำให้เกิดการผิดพลาดในจำแนก โรคเบาหวาน ซึ่งพบว่าข้อมูลแปรปรวนในระดับค่า อินซูลินในเลือด และอายุ เป็นต้น

รายการที่ 2 เกิดการผิดพลาดในจำแนกโรค พบว่าเกิดจาก ระดับกลูโคสในเลือด อยู่ในระดับสูงถึง

127 ระดับอายุก็สูงด้วย ทำให้เกิดการจำแนกที่ผิดพลาด ว่าเป็นโรคเบาหวาน แต่โดยความเป็นจริงระดับ กลูโคสในเลือด สูงมีโอกาสเป็นโรคเบาหวานสูงด้วย แต่ด้วยผลที่ถูกต้องกลับพบว่าไม่เป็นโรคเบาหวาน

รายการที่ 3 และ 4 พบว่าค่าน้ำตาลอยู่ในระดับต่ำ แต่มีปัจจัยอื่น ๆ มีความแปรปรวน เช่น อายุสูง จำนวน การตั้งครรภ์มีจำนวนมาก เป็นต้น ซึ่งจะทำให้เกิดการ ผิดพลาดในการจำแนกโรคเบาหวาน โดยการวิจัย พบว่าจะการวินิจฉัยการเป็นโรคเบาหวานหรือไม่เป็น โรคเบาหวานขึ้นอยู่กับหลายปัจจัยในการจำแนก ตลอดจนถึงขึ้นอยู่กับปัจเจกแต่ละบุคคลและแปรปรวน ของข้อมูลด้วย

อภิปรายผล

จากการวิจัยพบว่า การวินิจฉัยการเป็นโรคเบาหวาน หรือไม่เป็นโรคเบาหวานขึ้นอยู่กับการจำแนก และการวิจัยก็พบว่า การวินิจฉัยโรคเบาหวาน มีลักษณะแบบกึ่งโครงสร้าง เช่น การมีระดับค่าน้ำตาล ในกระแสเลือดเกิน 125 มิลลิกรัมต่อเดซิลิตร โดย

ส่วนใหญ่พบว่าถ้ามีค่าน้ำตาลเกินก็จะเป็นโรคเบาหวาน หรืออาจจะมีปัจจัยอื่น ๆ ร่วมด้วย เช่น การมีภาวะอ้วน การมีพันธุกรรมการเป็นโรคเบาหวาน และคนที่มียุมากกว่า 45 ปีขึ้นไป เป็นต้น

นอกจากนี้การวิจัยพบว่าวิธีการแบบ Naive Bayes เหมาะกับข้อมูลที่เป็นแบบเป็นข้อมูลต่อเนื่อง (continuous data) (Medium, 2023) วิธีการแบบ deep learning เหมาะสมกับการใช้ข้อมูลจำนวนมากในการเรียนรู้ (train) ซึ่งพบว่าจากข้อมูลในการจำแนกโรคเบาหวานมีข้อมูลจำนวนน้อยในการเรียนรู้ จึงทำให้ประสิทธิภาพไม่สูงมากนัก (Thai Programmer Association, 2023) และวิธีการแบบ support vector machine เหมาะสมกับข้อมูลที่เป็นลักษณะแบบอนุกรมเวลา (time series) เป็นต้น จากวิธีการวิจัยทั้งสามวิธีพบว่าประสิทธิภาพไม่สูงมากนักเนื่องจากพบว่าข้อมูลไม่เหมาะสมกับวิธีการ

ในการเรียนรู้ประเภทนี้ (Tepdang, & Ponprasert, 2022) และในส่วนของ logistic regression analysis เป็นวิธีการที่ประสิทธิภาพรองลงมาจาก gradient boosted trees เนื่อง logistic regression เหมาะสมกับข้อมูลเพื่อจำแนกว่าเป็นโรคหรือไม่เป็นโรค ซึ่งถือได้ว่ามีประสิทธิภาพดีในระดับหนึ่ง (Kasetsart University, 2018) และสุดท้ายวิธีการ gradient boosted trees มีประสิทธิภาพดีที่สุดใน เนื่องจากพบว่าข้อมูลการเป็นโรคเบาหวานมีลักษณะแบบกิ่งโครงสร้างซึ่งพบว่าเหมาะสมกับ วิธีการ gradient boosted trees มีลักษณะการเรียนรู้แบบโครงสร้างแบบต้นไม้ โดยจากระบบการประมวลผลได้สร้างโครงสร้างแบบต้นไม้ ดัง (Figure 3) ซึ่งมีการสร้างโครงสร้างแบบต้นไม้จำนวนมากในการจำแนกโรค ด้วยวิธี gradient boosted trees (Dhurakij Pundit University, 2023)

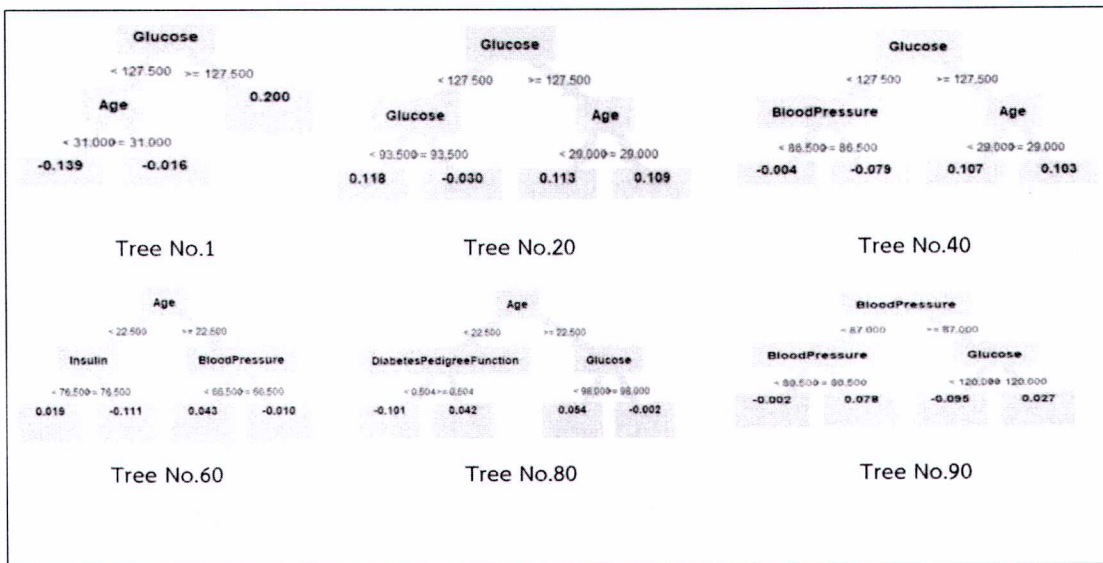


Figure 3 The tree of gradient boosted trees.

จากการวิจัยพบว่าได้สอดคล้องกับงานวิจัยในการพยากรณ์หรือการจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่อง โดยพบว่าการใช้วิธีแบบ gradient boosted trees มีประสิทธิภาพสูงที่สุดเมื่อเปรียบเทียบกับวิธีการอื่น ๆ ที่เรียนรู้ด้วยเครื่อง (Lai, Huang, Keshavjee, Guergachi, & Gao, 2019) และ (Selvi, & Muthulakshmi, 2021) และในส่วนของงานจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่องโดยการหาปัจจัยการคัดเลือกคุณลักษณะ พบว่าได้สอดคล้องกับงานวิจัย (Nagaraj, Deepalakshmi, Mansour, & Almazroa, 2021) ซึ่งพบว่าการใช้วิธีแบบ gradient boosted trees มีประสิทธิภาพดีที่สุดเช่นกัน แต่ในส่วนที่แตกต่างกันของการวิจัย คือ วิธีการหาปัจจัยการคัดเลือกคุณลักษณะจะใช้วิธีการหาแตกต่างกัน

สรุป

จากผลการวิจัยในครั้งนี้ การจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่อง โดยการหาปัจจัยการคัดเลือกคุณลักษณะพบว่าทำการเปรียบเทียบการเรียนรู้ด้วยเครื่องในการจำแนก 5 วิธี ได้แก่ Naive Bayes, logistic regression, deep learning, gradient boosted trees, SVM โดยวิธีที่ดีที่สุดคือ gradient boosted trees และการวิจัยได้แสดงให้เห็นการจำแนกในการหาปัจจัยการคัดเลือกคุณลักษณะ (feature selection) โดยการค่าน้ำหนักของข้อมูล ซึ่งจะใช้แบบ decision tree เพื่อการหาปัจจัยซึ่งเรียงลำดับจาก 8 ปัจจัย, 7 ปัจจัย, 6 ปัจจัย และจนไปถึง 3 ปัจจัย ตามลำดับ จากผลการวิจัยพบว่าใช้เพียง 4 ปัจจัยในการจำแนกมีประสิทธิภาพดีที่สุด

ได้แก่ ระดับค่ากลูโคสในเลือด อายุ จำนวนครั้งที่ตั้งครรภ์ และสุดท้ายระดับค่าอินซูลิน ซึ่งการวิจัยครั้งนี้พบว่ามีประสิทธิภาพในการจำแนกผู้ป่วยโรคเบาหวานได้ดี และยังพบอีกว่า การจำแนกผู้ป่วยโรคเบาหวานด้วยใช้วิธีการเรียนรู้ด้วยเครื่อง โดยการหาปัจจัยการคัดเลือกคุณลักษณะประสิทธิภาพดีกว่าการใช้วิธีการเรียนรู้ด้วยเครื่องเพียงอย่างเดียว อยู่ที่ 0.35 เปอร์เซ็นต์ ในส่วนของการจำแนกผิดพลาดพบว่าไม่มีกฎเกณฑ์แน่นอน และขึ้นอยู่กับปัจเจกแต่ละบุคคล ส่งผลทำให้การวินิจฉัยโรคเบาหวานผิดพลาด ดังนั้นแนวโน้มการวิจัยในอนาคต อาจหาวิธีการใหม่สำหรับการเรียนรู้ด้วยเครื่องและการหาปัจจัยการคัดเลือกคุณลักษณะเพื่อช่วยเพิ่มประสิทธิภาพในการจำแนกโรคให้ดีขึ้น ผลที่ได้จากการวิจัยสามารถนำไปใช้ในกลุ่มเสี่ยงเพื่อการจำแนกผู้ป่วยโรคเบาหวานได้ และถ้าสามารถจำแนกผู้ป่วยโรคเบาหวานได้อย่างรวดเร็วก็จะสามารถวางแผนการรักษา จะทำให้ผู้ป่วยสามารถรักษาหายและมีอายุยืนยาวมากขึ้น

เอกสารอ้างอิง

- ABB. (2023). *Deep learning*. Retrieved 14 January 2023, from <https://new.abb.com/news/detail/58004/deep-learning> (in Thai)
- Bureau of Information Office of the Permanent Secretary. (2020). *Diabetes mellitus*. Retrieved 14 December 2022, from <https://pr.moph.go.th/?url=pr/detail/2/02/181256/> (in Thai)
- Butt, U. M., Letchmunan, S., Ali, M., Hassan, F. H., Baqir, A., & Sherazi, H. H. R. (2021). Machine learning based diabetes classification and prediction for healthcare applications. *Journal of Healthcare Engineering*, 2021, 9930985.

- Dataset. (2023). *Diabetes mellitus*. Retrieved 14 December 2022, from <https://www.kaggle.com/datasets/akshaydattatraykhare/diabetes-dataset>
- Dhurakij Pundit University. (2023). *Gradient boosted trees*. Retrieved 14 January 2023, from <https://grad.dpu.ac.th/upload/content/files/year9-3/9-30.pdf> (in Thai)
- Glurgeek. (2023). *Support vector machine (SVM)*. Retrieved 14 January 2023, from <https://www.glugreek.com/education/support-vector-machine/> (in Thai)
- Kasetsart University. (2018). *Logistic regression*. Retrieved 14 January 2023, from <https://forest-admin.forest.ku.ac.th/304xxx/?q=system/files/book/5%282018%29%20Logistic%20Regression.pdf> (in Thai)
- Lai, H., Huang, H., Keshavjee, K., Guergachi, A., & Gao, X. (2019). Predictive models for diabetes mellitus using machine learning techniques. *BMC Endocrine Disorders*, 19, 101.
- Medium. (2023). *Naïve Bayes classification*. Retrieved 14 January 2023, from <https://peachapongpoolpol.medium.com/na%C3%AFve-bayes-classification-cb6cf905505d> (in Thai)
- Nagaraj, P., Deepalakshmi, P., Mansour, R. F., & Almazroa, A. (2021). Artificial flora algorithm-based feature selection with gradient boosted tree model for diabetes classification. *Diabetes, Metabolic Syndrome and Obesity*, 14, 2789-2806.
- Nonsiri, N., Chaichitwanidchakol, P., & Somkantha, K. (2022). Data classification for diabetes risk diagnosis using majority voting ensemble method and forward feature selection method. *Udon thani Rajabhat University Journal of Sciences and Technoogy*, 10(2), 107-122.
- Phuket Hospital. (2022). *Diabetes mellitus*. Retrieved 14 December 2022, from <https://www.phukethospital.com/th/news-events/diabetes/> (in Thai)
- Rawat, V., & Suryakant, S. (2019). A classification system for diabetic patients with machine learning techniques. *International Journal of Mathematical, Engineering and Management Sciences*, 4(3), 729-744.
- Rubaiat, S. Y., Rahman, M. M., & Hasan, M. K. (2018). Important feature selection & accuracy comparisons of different machine learning models for early diabetes detection. *International Conference on Innovation in Engineering and Technology* (pp.1-6). Dhaka, Bangladesh: IEEE.
- Saxena, R., Sharma, S. K., Gupta, M., & Sampada, G. C. (2022). A novel approach for feature selection and classification of diabetes mellitus: Machine learning methods. *Computational Intelligence and Neuroscience*, 2022(Special issue), 3820360.
- Selvi, R. T., & Muthulakshmi, I. (2021). Modelling the map reduce based optimal gradient boosted tree classification algorithm for diabetes mellitus diagnosis system. *Journal of Ambient Intelligence and Humanized Computing*, 12, 1717-1730.
- Sidong, W., Xuejiao, Z., & Chunyan, M. (2018). A comprehensive exploration to the machine learning techniques for diabetes identification. *2018 IEEE 4th World Forum on Internet of Things (WF-IoT)* (pp. 291-295). Singapore: IEEE.
- Tepdang, S., & Ponprasert, R. (2022). Forecasting and clustering of cassava price by machine learning (A study of Cassava prices in Thailand). *Indonesian Journal of Electrical Engineering and Informatics*, 10(4), 825-836.
- Thai Programmer Association. (2023). *Deep learning*. Retrieved 14 December 2022, from <https://www.thaiprogrammer.org/2018/12/deep-learning>

- Thatoom Hospital. (2014). *Diabetes mellitus*. Retrieved 14 December 2022, from <http://www.thatoomhsp.com/> (in Thai)
- Th.Linkedin. (2023). *Feature selection*. Retrieved 14 January 2023, from <https://th.linkedin.com/pulse/> (in Thai)
- Th.Wikipedia. (2021). *Decision tree*. Retrieved 14 December 2022, from <https://th.wikipedia.org/wiki/>