

การใช้ Machine learning เพื่อทำนายพาหะแอลฟาธาลัสซีเมียในหญิงตั้งครรภ์ ที่มาฝากครรภ์กับโรงพยาบาลแพร์

ประเสริฐ จันทนสกุลวงศ์ วท.ม.¹, ธนวัฒน์ชัย สุริยะ วท.บ.¹, สกุรัตน์ อริยะเพชร วท.บ.¹

รับบทความ: 16 กันยายน 2567

ปรับแก้บทความ: 8 ตุลาคม 2567

ตอบรับบทความ: 17 ตุลาคม 2567

บทคัดย่อ

- บทนำ:** การตรวจคัดกรองพาหะแอลฟาธาลัสซีเมียเบื้องต้น ใช้ค่า MCV < 80 fl และ DCIP test ให้ผล positive ซึ่งมีความแม่นยำต่ำ ปัจจุบันมีการใช้ Machine learning (ML) ช่วยในการคัดกรองซ้ำมากขึ้น
- วัตถุประสงค์:** เพื่อสร้างและค้นหาแบบจำลองที่ดีที่สุดของ Machine learning ที่ให้ประสิทธิภาพดีที่สุดในการทำนายพาหะแอลฟาธาลัสซีเมียในหญิงตั้งครรภ์
- วิธีการศึกษา:** เป็นการศึกษาแบบ Diagnostic research รวบรวมข้อมูลแบบ cross-sectional จากข้อมูลหญิงตั้งครรภ์และสามี ตั้งแต่ปี 2557-2566 จำนวน 592 คู่ 1184 ราย เลือกข้อมูล จำนวน 161 ราย alpha-thal trait vs non alpha-thal trait (66 : 95) ใช้ค่าการตรวจเม็ดเลือดแดงพื้นฐาน HCT, HGB, RBC, MCV, MCH, MCHC, RDW และอายุ AGE สร้างแบบจำลอง ML algorithms ให้เครื่องคอมพิวเตอร์เรียนรู้และทำนาย ด้วยภาษา Python ในโปรแกรม Google colab แสดงประสิทธิภาพของแบบจำลองด้วยค่า accuracy (ACC), sensitivity (Sn), specificity (Sp), area under ROC curve (AUC)
- ผลการศึกษา:** พบว่าชุด dataset ที่ศึกษา (66:95) แบ่งข้อมูล train: test set (80:20) ML ให้ประสิทธิภาพในการทำนายพาหะแอลฟาธาลัสซีเมีย โดยมีค่า ACC, Sn, Sp, AUC ดังนี้ DT: 97,100,95,0.9643, RF: 97,100,95,1.0000 ADA: 97,100,95,0.9737 XGB: 97,100,95,0.9699 LR: 97,100,95,0.9963 DL: 93.9,100,90.5,0.9774 และ SVM: 97,100,95,1.0000
- สรุป:** แบบจำลองที่ให้ประสิทธิภาพที่ดีที่สุด คือ ADA ให้ความถูกต้องในการทำนายสูงถึง 97% สามารถลดค่าใช้จ่ายการตรวจยืนยันด้วยวิธี PCR ในรายที่ผลทำนายเป็น non alpha thalassemia carrier ได้
- คำสำคัญ:** การเรียนรู้ของเครื่อง, พาหะแอลฟาธาลัสซีเมีย, ภูเก็ต โคแลป, หญิงตั้งครรภ์

A Machine learning for predicting alpha thalassemia carrier in a pregnant woman at prenatal care, Phrae Hospital

Prasert Chantanaskulwong M.Sc., Tanawatthai Suriya B.Sc., Sakulrhat Ariyapetch B.Sc.

Received: September 26, 2024

Revised: October 8, 2024

Accepted: October 17, 2024

Abstract

Background: Screening for alpha thalassemia carriers uses MCV and DCIP test, which are low- accuracy. Currently, Machine learning is increasingly being used.

Objective: To create and find the best machine learning model that performs best in predicting alpha thalassemia carriers.

Study design: This paper is a Diagnostic research study. Data were collected. Cross-sectional from data on pregnant women and their husbands from 2014-2023, 592 couples, 1184 cases, selected data for 161 cases, alpha-thal trait vs non-alpha-thal trait (66:95), using basic red blood cell test values HCT, HGB, RBC, MCV, MCH, MCHC, RDW and AGE. To create ML algorithms models for computers to learn and make predictions using the Python language in the Google Colab program. Show the performance of the models with accuracy, sensitivity, specificity and area under ROC curve.

Result: It was found that the studied dataset (66:95) divided into train:test set (80:20) ML data provided efficiency in predicting alpha thalassemia carriers as follows: DT: ACC, Sn, Sp, AUC DT: 97,100,95,0.9643, RF: 97,100,95,1.0000 ADA: 97,100,95,0.9737 XGB: 97,100,95,0.9699 LR: 97,100,95,0.9963 DL: 93.9,100, 90.5 ,0.9774 and SVM: 97,100,95,1.0000.

Conclusion: ADA is the best performance, with a prediction accuracy of up to 97%. It can reduce the cost of PCR tests in non-alpha thalassemia carriers.

Keywords: machine learning, alpha thalassemia trait, google colab, pregnant women

¹Department of Medical Technology and Clinical Pathology, Phrae Hospital

บทนำ

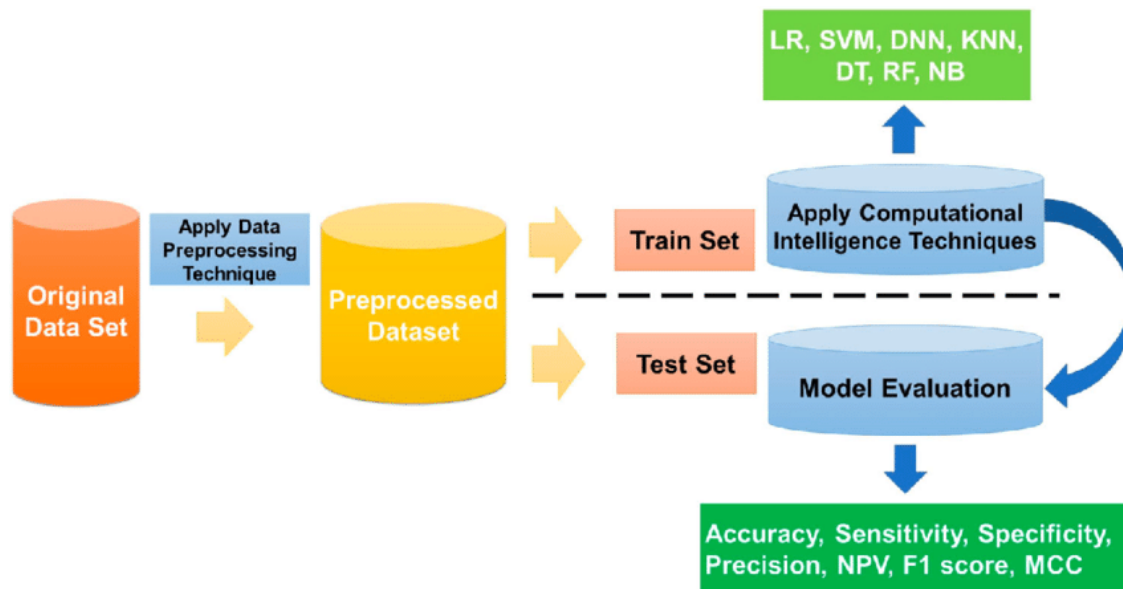
ในการคัดกรองพาหะธาลัสซีเมีย หากพบว่า เม็ดเลือดแดงมีขนาดเล็กกว่า 80 fl (MCV \leq 80 fl) ต้องได้รับการตรวจวินิจฉัยด้วยการตรวจวิเคราะห์ฮีโมโกลบิน (hemoglobin analysis) ร่วมกับการวัดสัดส่วนของฮีโมโกลบิน A2 โดยการตรวจโดยเครื่องอัตโนมัติ high pressure liquid column chromatography (HPLC) จะสามารถวินิจฉัยชนิดของพาหะเบต้าธาลัสซีเมีย และพาหะฮีโมโกลบิน อี ได้ ในส่วนการวินิจฉัย พาหะของแอลฟาธาลัสซีเมีย 1 (α -thalassemia 1 carrier) ต้องใช้การตรวจความผิดปกติในระดับยีนโดยวิธี polymerase chain reaction (PCR)^(1,2) โดยในประเทศไทย จะตรวจเฉพาะชนิด Southeast Asian (SEA) deletion และ Thai deletion เนื่องจากเป็น 2 ชนิดที่พบบ่อย ในปัจจุบันทั้งพาหะเบต้าธาลัสซีเมีย และพาหะแอลฟาธาลัสซีเมีย 1 ยังคงใช้เกณฑ์ของ MCV ในการคัดกรองค่าเดียวกัน คือ น้อยกว่า 80 fl อย่างไรก็ตาม ในอดีตมีการศึกษาของยุพิน ใจแปง และคณะ⁽³⁾ เมื่อปี 2559 ใช้ชุดตรวจ IC-Strip มาช่วยตรวจคัดกรองเพื่อลดจำนวนการส่งตรวจ PCR for alpha thalassemia 1 ศึกษาในศูนย์อนามัยแม่และเด็กที่ 1, 3, 5, 7 ให้ประสิทธิภาพการคัดกรองได้ดีขึ้น มีความแม่นยำ $>70\%$ แต่ต้องตรวจในหลอดเลือดที่เจาะใหม่⁽³⁾ และเร็ว ๆ นี้ ปี 2563 ฉันทหทัย นันทชัย และคณะ⁽⁴⁾ ใช้ค่า MCV <76.15 fl ในการคัดกรองหญิงตั้งครรภ์ที่ภาควิชาสูติศาสตร์และนรีเวชวิทยา คณะแพทยศาสตร์ มหาวิทยาลัยเชียงใหม่ สามารถลดจำนวนการส่งตรวจ PCR for alpha thal ได้ร้อยละ 40 โดยไม่ลดประสิทธิภาพการควบคุมและป้องกันโรคเลือดจางธาลัสซีเมีย

ปัจจุบันเทคโนโลยีคอมพิวเตอร์ได้พัฒนาอย่างรวดเร็ว โดยเฉพาะ ML, AI และวิทยาศาสตร์ข้อมูล (data science) เหมือนข้อมูล (data mining) มีการนำ AI มาช่วยในการแก้ปัญหาด้านสุขภาพมากขึ้นการเรียนรู้ของเครื่อง (ML) คือ การประยุกต์คณิตศาสตร์และวิทยาศาสตร์คอมพิวเตอร์ เพื่อทำให้คอมพิวเตอร์สามารถเรียนรู้และตัดสินใจได้ โดยไม่ต้องกำหนดกฎและเงื่อนไขตามตัวโดยการใช้ข้อมูลที่มนุษย์เตรียมให้ และประมวลผลข้อมูลเพื่อตัดสินใจตามที่ต้องการ เช่น เพื่อทำนายหรือพยากรณ์ ข้อมูลใหม่ที่เครื่องไม่เคยเรียนรู้มาก่อนสามารถสร้างแบบจำลอง ML ตั้งแต่แบบง่าย LR, DT, SVM ไปจนถึงแบบที่ซับซ้อน ADA, DL⁽⁴⁸⁾ การศึกษาที่ผ่านมา พบว่า มีประสิทธิภาพในการคัดกรองพาหะแอลฟาธาลัสซีเมียได้ดีขึ้น $>70\%$ แต่ยังไม่ดีที่สุด

การศึกษาวิจัยครั้งนี้มีวัตถุประสงค์ เพื่อสร้างและทดสอบประสิทธิภาพของแบบจำลอง Machine learning ที่ดีที่สุดในการทำนายพาหะแอลฟาธาลัสซีเมียในหญิงตั้งครรภ์โรงพยาบาลแพร่

วัสดุและวิธีการ

เป็น Diagnostic research เก็บข้อมูลแบบ cross sectional จากข้อมูลหญิงตั้งครรภ์และสามีที่ตรวจคัดกรองตั้งแต่ปี 2557 ถึง 2566 โดยใช้ ค่าการตรวจเม็ดเลือดพื้นฐาน CBC ตัวแปรที่ใช้ในการทำนาย คือ Age, Hct, Hb, RBC, MCV, MCH, MCHC และ RDW-CV ซึ่งโรงพยาบาลแพร่ใช้เครื่องตรวจนับเม็ดเลือดอัตโนมัติ Mindray BC 6800 และผลการตรวจยืนยันว่าเป็น แอลฟาธาลัสซีเมีย ด้วยวิธี PCR มาตรฐาน จากภาควิชาสูติศาสตร์และนรีเวชวิทยา คณะแพทยศาสตร์ มหาวิทยาลัยเชียงใหม่ ตาม Study flow (รูปที่ 1)



รูปที่ 1 แสดง Study flow ของการศึกษา

ประเมินประสิทธิภาพของแบบจำลอง ML ด้วย accuracy (ACC), sensitivity (Sn), specificity (Sp) Matthews correlation coefficient (MCC)

$$ACC = (TP + TN)/(TP + TN + FP + FN) \quad (1)$$

$$Sn = TP/(TP + FN) \quad (2)$$

$$Sp = TN/(TN + FP) \quad (3)$$

$$MCC = (TP * TN - FP * FN) / \text{sqrt}((TP + FP)(TP + FN)(TN + FP)(TN + FN)) \quad (4)$$

พิทักษ์สิทธิและจริยธรรมการวิจัย

งานวิจัยนี้ได้รับการรับรองโครงการวิจัยในมนุษย์โดยคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ โรงพยาบาลแพร่ หมายเลขใบรับรอง 65/2567

ผลการศึกษา

ข้อมูลหญิงตั้งครรภ์และสามี คู่เสี่ยงที่ตรวจคัดกรองด้วย Screening test MCV <80 fl และ DCIP test ให้ผลบวกทั้งสองการทดสอบหรือให้ผลบวกกับการทดสอบอย่างใดอย่างหนึ่ง มีภาวะเสี่ยงที่เป็นพาหะธาลัสซีเมียชนิดใดชนิดหนึ่ง

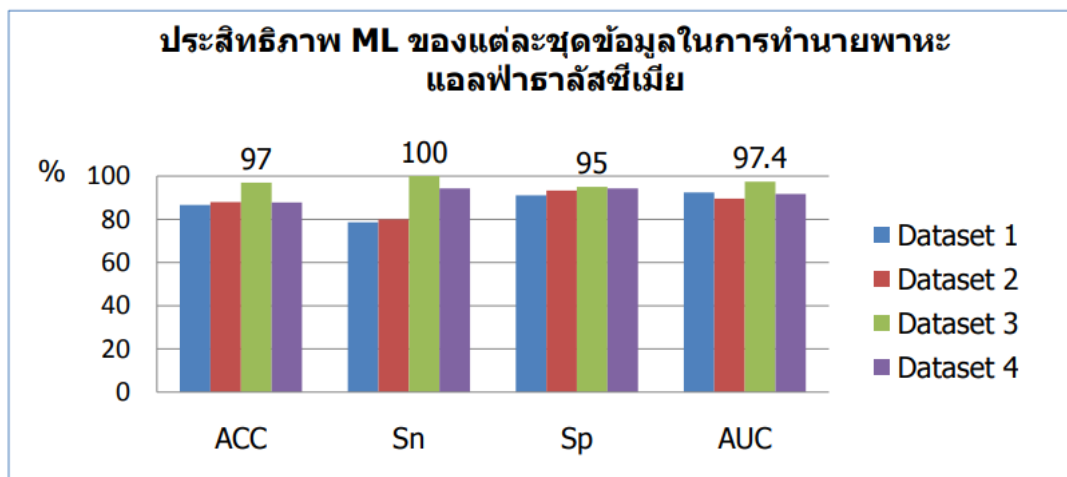
จากห้องปฏิบัติการโลหิตวิทยาและจุลทรรศน์ศาสตร์ โรงพยาบาลแพร่ ต้องส่งตรวจ Hb typing, PCR for alpha thalassemia (SEA, Thai deletion type) และวิเคราะห์ความเสี่ยงที่จะมีบุตรเป็นโรคเลือดจางธาลัสซีเมียชนิดรุนแรง 3 ชนิด ตามโครงการควบคุมและป้องกันโรคธาลัสซีเมียของกรมอนามัย กระทรวงสาธารณสุข ณ ศูนย์วิจัยธาลัสซีเมีย คณะแพทยศาสตร์ มหาวิทยาลัยเชียงใหม่ จากสถิติย้อนหลัง 10 ปี ตั้งแต่ปี 2557-2566 จำนวน 592 คู่ 1184 คน (ตารางที่ 1)

ตารางที่ 1 ลักษณะของธาลัสซีเมียชนิดต่าง ๆ ที่พบในห้องปฏิบัติการโลหิตวิทยาและจุลทรรศน์ศาสตร์ โรงพยาบาลแพร่ ปี 2557-2566

Diagnosis	Hb typing	PCR for SEA	PCR for Thai	Number	Percent
Normal	A2A	Negative	Negative	402	33.9
Hb E trait	EA	Negative	Negative	370	31.2
Alpha thal trait	A2A	Positive	Negative	179	15.1
Beta thal trait	A2A	Negative	Negative	122	10.3
HbE trait + alpha	EA	Positive	Negative	43	3.6
Beta thal trait + alpha	A2A (Hb A2 >3.5%)	Positive	Negative	14	1.2
อื่น ๆ	EE	Negative	Negative	30	4.6
	EF	Negative	Negative	6	
	A2AH,CSA2AH	Positive	Negative	8	
	EE + alpha	Positive	Negative	4	
	EF + alpha	Positive	Negative	2	
	A2A +Abnormal Hb	Negative	Negative	2	
	Hb Q Thailand	Negative	Negative	1	
	A2FA + alpha	Positive	Negative	1	
Total				1184	100.0

การศึกษานี้แบ่งข้อมูลเป็น dataset 4 ชุด ชุดที่ 1 alpha-thal carriers vs non-alpha thal carriers (56 : 117) ชุดที่ 2 (41 : 82) ชุดที่

3 (66 : 95) และ ชุดที่ 4 (117 : 438) ตามลำดับ (รูปที่ 2)



รูปที่ 2 แสดงประสิทธิภาพของMachine learning ใน dataset ที่ทำการศึกษา

ผลการศึกษา dataset ชุดที่ 3 พบลักษณะที่คล้ายคลึงกันระหว่างกลุ่ม non-alpha-thal trait และ alpha-thal trait ได้แก่ ตัวแปร อายุ (Age) และ

Hematocrit (HCT) ($p=0.544$, 0.306) ส่วน HGB, RBC, MCV, MCH, MCHC, RDW ทั้ง 2 กลุ่มแตกต่างกัน อย่างมีนัยสำคัญทางสถิติ (ตารางที่ 2)

ตารางที่ 2 ลักษณะทั่วไปของข้อมูล กลุ่มทดลองและกลุ่มควบคุม ระหว่าง Alpha trait vs normal II

ลักษณะที่ใช้ศึกษา	non alpha-thal trait (n=95)	Alpha-thal trait (n=66)	p-value
Age	28.2 (± 6.5)	28.9 (± 6.3)	0.5437
HCT	38.7 (± 5.4)	37.8 (± 4.9)	0.3062
HGB	13.0 (± 1.8)	12.3 (± 1.7)	0.0155
RBC	5.21 (± 0.7)	5.93 (± 0.6)	<0.0001
MCV	74.8 (± 4.3)	63.8 (± 5.3)	<0.0001
MCH	25.1 (± 1.5)	20.7 (± 1.9)	<0.0001
MCHC	33.6 (± 0.9)	32.5 (± 1.1)	<0.0001
RDW	14.5 (± 2.0)	16.6 (± 2.6)	<0.0001

เมื่อนำข้อมูลมาสร้างแบบจำลองการเรียนรู้ของเครื่องชนิดต่าง ๆ ด้วยโปรแกรม Google colab โดยใช้ code ภาษา Python แบบจำลองทุกประเภทให้ประสิทธิภาพของการทำนายแยก

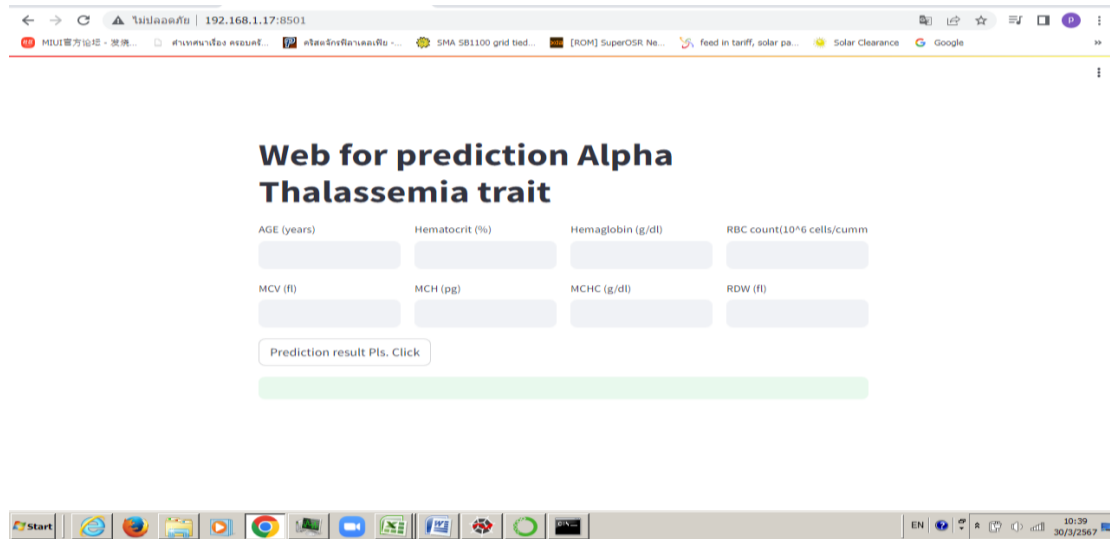
ระหว่าง ผู้ที่เป็นพาหะแอลฟาธาลัสซีเมีย ออกจากผู้ที่ไม่เป็นพาหะได้ดี ด้วย % accuracy, % sensitivity, % specificity และ AUC ที่สูงเท่ากับ 97%, 100%, 95% และ 0.974 ตามลำดับ (ตารางที่ 3)

ตารางที่ 3 แสดงประสิทธิภาพของแบบจำลองที่ใช้ในการทำนาย datasets ชุดที่ 3

ML algorithms	ACC (%)	Sn (%)	Sp (%)	MCC	AUC
DT	97.0	100.0	95.0	0.939	0.964
RF	97.0	100.0	95.0	0.939	1.000
ADA	97.0	100.0	95.0	0.939	0.974
XGB	97.0	100.0	95.0	0.939	0.970
LR	97.0	100.0	95.0	0.939	0.996
DL	93.9	100.0	90.5	0.881	0.977
SVM	97.0	100.0	95.0	0.939	1.000

แบบจำลองที่ดีที่สุดสำหรับการทำนายพาหะแอลฟาธาลัสซีเมีย ที่เลือกใช้ในการศึกษานี้ คือ Adaboost ซึ่งสามารถนำไปเผยแพร่ผ่าน Web

application ได้ผ่านการใช้นำคำสั่ง Streamlit run (รูปที่ 3)



รูปที่ 3 Web application สร้างผ่าน Code streamlit run ในโปรแกรม anaconda 2.0.3

การแบ่งข้อมูลเป็น train set และ test set ในอัตราส่วนอื่น ๆ พบว่า การแบ่งข้อมูลเป็น train set 90 ต่อ test set 10 ให้ประสิทธิภาพใน

การทำนายได้ดีที่สุด โดยพบค่า Acc, Sn, Sp, และ AUC เท่ากับ 100%, 100%, 100% และ 1.000 ตามลำดับ (ตารางที่ 4)

ตารางที่ 4 แสดงประสิทธิภาพของแบบจำลอง ADA แบ่งข้อมูลเป็นชุดเรียนรู้ (train set): ชุดทดสอบ (test set) ในสัดส่วนต่าง ๆ ของ datasets ชุดที่ 3

ML algorithms	Acc (%)	Sn (%)	Sp (%)	MCC	AUC
ADA(0,90)	89.7	94.1	87.2	0.667	0.927
ADA(0.80)	93.0	92.6	93.3	0.857	0.928
ADA(0.70)	92.9	93.3	92.6	0.854	0.942
ADA(0.60)	95.8	92.3	98.2	0.914	0.962
ADA(0.50)	95.1	96.5	94.1	0.897	0.967
ADA(0.40)	96.9	96.3	97.4	0.937	0.957
ADA(0.30)	98.0	100.0	96.6	0.959	0.981
ADA(0.20)	97.0	100.0	95.0	0.939	0.974
ADA(0.10)*	100.0	100.0	100.0	1.000	1.000

วิจารณ์

ในการศึกษาครั้งนี้ เก็บข้อมูลย้อนหลัง 10 ปี ตั้งแต่ปี 2557-2566 ของหญิงตั้งครรภ์ที่มาฝากครรภ์กับโรงพยาบาลแพร์ และสามี และผ่านการตรวจคัดกรองตามโครงการควบคุมและป้องกันโรคธาลัสซีเมีย

ของกรมอนามัย พบว่า มีหญิงตั้งครรภ์ และสามี ที่ตรวจคัดกรองที่สงสัยว่าจะเป็นพาหะชนิด alpha thalassemia หรือ พาหะชนิด beta thalassemia, ชนิด Abnormal Hb (HbE) ร้อยละ 34.8 และไม่ เป็นพาหะ ร้อยละ 33 การคัดกรองหญิงตั้งครรภ์

และสามี่ขึ้นโดยใช้การเรียนรู้ของเครื่อง (ML) ซึ่งมีการศึกษาในระยะ 2-3 ปีที่ผ่านมา มีการศึกษาเกี่ยวกับการใช้ ML เพื่อทำนายการเป็น พาหะ alpha thalassemia, พาหะ beta thalassemia มากขึ้นทั้งในประเทศไทย⁽⁴⁾ ประเทศจีน และประเทศอินเดีย⁽⁵⁾ จากการศึกษาครั้งนี้ พบว่า dataset แต่ละชุดให้ผลการทำนาย พาหะ alpha thalassemia SEA type ได้แตกต่างกัน จำนวนของข้อมูลใน dataset ให้ประสิทธิภาพในการทำนายแตกต่างกัน dataset จำนวนมากอาจให้ประสิทธิภาพที่ดี หรือ อาจให้ประสิทธิภาพการทำนายต่ำกว่าก็ได้ ซึ่งพบว่าลักษณะของข้อมูล HGB ใน dataset ชุดที่ 1 กลุ่ม alpha-thal carriers (n=96)/กลุ่ม non-alpha-thal carriers (n=188), ชุดข้อมูลที่ 3 กลุ่ม alpha-thal carriers (n=66)/กลุ่ม non-alpha-thal carriers (n=95) และ ชุดข้อมูลที่ 4 กลุ่ม alpha-thal carriers (n=177)/กลุ่ม non-alpha-thal carriers (n=438) ให้ค่า p-value = 0.049, 0.016 และ 0.001 ยิ่งมีความแตกต่างกันมากอาจจะให้ประสิทธิภาพการทำนายที่ถูกต้องมากขึ้นแต่ไม่ขึ้นอยู่กัจำนวนของข้อมูลใน dataset ส่วนการแบ่งข้อมูลเป็น train set ต่อ test set พบว่า ยิ่งแบ่งข้อมูลให้ train set มาก ประสิทธิภาพของการเรียนรู้ของเครื่องจะสูงขึ้น โดยเฉพาะสัดส่วน train set: test set เท่ากับ 70:30, 80:20 และ 90:10 ตามลำดับ

การใช้ ML เพื่อทำนาย alpha-thal carriers ชนิด SEA type ในการศึกษาครั้งนี้ ได้ แบบจำลอง algorithm ทางคณิตศาสตร์ ที่สามารถแยก alpha-thal carriers ชนิด SEA type ออกจากกลุ่มที่เป็น non-alpha-thal carriers ได้อย่างน่าสนใจ จากการใช้ parameters ที่ตรวจจาก CBC ของหญิงตั้งครรภ์และสามี่ รวมถึงอายุ ซึ่งปัจจุบันเทคโนโลยี AI ในด้าน Machine learning สามารถทำได้ดีกว่ามนุษย์ แบบจำลอง ML ที่ค้นพบสามารถนำไปใช้ช่วยคัดกรองหญิงตั้งครรภ์และสามี่ ในการลดจำนวนสิ่งส่งตรวจที่เป็นพาหะ

alpha thalassemia ชนิด SEA type ในขั้นตอนส่งตรวจ PCR ได้ระดับหนึ่ง และลดค่าใช้จ่ายในการควบคุมป้องกันโรคธาลัสซีเมียได้ การศึกษาวิจัยในอนาคตควรมี การใช้ Machine learning เพื่อทำนายพาหะเบต้าธาลัสซีเมียในหญิงตั้งครรภ์และสามี่ที่มาฝากครรภ์กับโรงพยาบาลแพร์ ใช้ชุดข้อมูลพาหะ beta-thal carriers vs ข้อมูล non-beta-thal carriers และสร้างผลทำนายผ่าน Web app ได้

สรุป

การใช้ Machine learning เพื่อทำนาย alpha thalassemia 1 carriers ชนิด SEA type สามารถทำนายหญิงตั้งครรภ์และสามี่ได้ โดยใช้แบบจำลอง ADABOOST ในชุดข้อมูลที่ 3 ซึ่งให้ประสิทธิภาพดีมาก คือ ACC=97%, Sn=100%, Sp=95% และ AUC=974 สามารถ Deploy ML ผ่าน code streamlit run ในโปรแกรม anaconda navigator 2.0.3 โดยใช้เวลาในการทำนายผลได้อย่างรวดเร็ว เมื่อทดลองนำข้อมูลการตรวจ CBC ในหญิงตั้งครรภ์ และสามี่ ที่ส่งตรวจ PCR for alpha thalassemia ได้ผลทำนาย ใน case ที่เป็น non alpha thalassemia carrier สามารถลดการตรวจ PCR ได้ 70%

กิตติกรรมประกาศ

ขอขอบคุณคณะกรรมการวิจัยโรงพยาบาลแพร์ และคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ โรงพยาบาลแพร์ที่อนุญาตให้ทำการศึกษาในครั้งนี้ ใบรับรอง เลขที่ 65/2567 ขอขอบคุณ อ.ศ.ดร.สุรางค์รัตน์ พ้องพาน และ อ.ดร.พัชรินทร์ คำนวล ที่ให้คำแนะนำการดำเนินการวิจัย ขอขอบคุณกลุ่มงานเทคนิคการแพทย์และพยาธิวิทยาคลินิก เพื่อนร่วมงาน และทีมวิจัยทุกท่านที่ให้การสนับสนุนในทุกด้าน

เอกสารอ้างอิง

1. สิริภากร แสงกิจพร. คู่มือทางห้องปฏิบัติการการตรวจวินิจฉัยธาลัสซีเมียและการการตรวจวินิจฉัยธาลัสซีเมียและฮีโมโกลบินผิดปกติ ฉบับปรับปรุง 2567. พิมพ์ครั้งที่ 9. กรุงเทพฯ: พรีเมียร์ มาร์เก็ตติ้ง โซลูชั่น; 2567.
2. ต่อพงศ์ สงวนเสริมศรี. ภาวะพาหะของโรคธาลัสซีเมีย. วารสารโลหิตวิทยาและเวชศาสตร์บริการโลหิต 2557;24(4):329-32.
3. Jopang Y, Pinmuang-ngam C, Suksaweang S, Khongthai K, Techachainiran B, Chewasateanchai M, et al. Accuracy of Immunochromatographic Strip Test for Screening of alpha thalassemia 1 Carriers at the Rural Clinical Settings. J Med Tech Assoc Thailand 2016; 44(2):5600-5607.
4. Laengsri V, Shoombuatong W, Adirojananon W, Nantasenamat C, Prachayasittikul, Nuchnoi P. ThalPred: a web-based prediction tool for discriminating thalassemia trait and iron deficiency anemia. BMC Med Inform Decis Mak 2019;19(1):212. doi:10.1186/s12911-019-0929-2.
5. Phirom K, Charoenkwan P, Shoombuatong W, Charoenkwan P, Sirichotiyakul S, Tongsong T. DeepThal: A Deep Learning-Based Framework for the Large-Scale Prediction of the α + - Thalassemia Trait Using Red Blood Cell Parameters. Journal Clinical Medicine 2022;11(21):6305. doi.org/10.3390/jcm11216305
6. Saleem M, Aslam W, Lail MIU, Rauf HT, Nasr EA. Predicting Thalassemia Using Feature Selection Techniques: A Comparative Analysis. Diagnostics 2023;13(22):3441.doi:10.3390/diagnostics13223441
7. ชิตพงษ์ กิตตินราดร. Categorical Encoding [อินเทอร์เน็ต]. 2562 [สืบค้นเมื่อ 8 เมษายน 2567]. สืบค้นจาก: <https://guopai.github.io/ml-blog01.html>
8. Naik PG, Naik GR, Patil MB. Conceptualizing Python in Google COLAB. India: Shashwat Publication; 2021.