

## การใช้การเรียนรู้ของเครื่องจักรเพื่อหาปัจจัยเสี่ยงต่อการให้เลือด ในผู้ป่วยกระดูกสะโพกหักที่ได้รับการผ่าตัดข้อสะโพกเทียม Machine Learning Risk Factors for Blood Transfusion After Hip Arthroplasty in Fracture Neck Femur Patients

พลสันต์ สันธนิพัฒน์กุล พ.บ.,  
วว. ออร์โธปิดิกส์  
กลุ่มงานศัลยกรรมกระดูก  
โรงพยาบาลสมุทรสาคร  
จังหวัดสมุทรสาคร

Polasan Santanapipatkul M.D.,  
Dip., Thai Board of Orthopaedics  
Division of Orthopaedic Surgery  
Samutsakorn Hospital  
Samut Sakorn

### บทคัดย่อ

**วัตถุประสงค์:** เพื่อศึกษาปัจจัยเสี่ยงต่อการได้รับเลือดในผู้ป่วยสะโพกหักที่ได้รับการผ่าตัดข้อสะโพกเทียม โดยการใช้การเรียนรู้ของเครื่องจักร (machine learning)

**วิธีการศึกษา:** เป็น retrospective study โดยศึกษาข้อมูลจากเวชระเบียนผู้ป่วยที่สะโพกหัก และได้รับการผ่าตัดข้อสะโพกเทียม ที่โรงพยาบาลสมุทรสาคร ในช่วง พ.ศ. 2558–2563 จำนวน 232 คน

**ผลการศึกษา:** เพศชาย, โรคไต, และข้อสะโพกเทียมชนิดใส่ซีเมนต์ เป็นปัจจัยเสี่ยงต่อการได้รับเลือด เพศชาย, โรคไต, โรคหัวใจขาดเลือด, ข้อสะโพกเทียมชนิดใส่ซีเมนต์, และASA เป็นปัจจัยสำคัญในการพยากรณ์ความเสี่ยงต่อการได้รับเลือด

**สรุป:** ในผู้ป่วยที่มีปัจจัยเสี่ยงต่อการได้รับเลือด ถ้าสามารถลดปัจจัยเสี่ยงก็น่าจะลดความเสี่ยงต่อการให้เลือดได้ รวมทั้งลดค่าใช้จ่ายและภาวะแทรกซ้อนจากการให้เลือดได้ด้วย

**คำสำคัญ :** การเรียนรู้ของเครื่องจักร ปัจจัยเสี่ยง กระดูกสะโพกหัก ข้อสะโพกเทียม

วารสารแพทยเขต 4-5 2564 ; 40(3) : 381–88.

### Abstract

**Objective:** The purpose is to study risk factors for blood transfusion in hip arthroplasty in fracture neck of femur patients by machine learning.

**Method:** This is a retrospective study by collecting the data of fracture neck of femur patients underwent hip arthroplasty surgery at Samutsakhorn Hospital from 2015 to 2020 A.D. ; 232 patients were analysed.

**Result:** Male, CKD, and cemented prostheses increase risk for blood transfusion significantly. According to machine learning; male, CKD, ischemic heart disease, cemented prostheses, and ASA are important factors for predicting risk for blood transfusion.

**Conclusion:** In patients with risk factors, modifying the risk factors will decrease blood transfusion and also reduce cost and complication from blood transfusion.

**Keyword :** machine learning, risk factor, fracture neck of femur, hip arthroplasty

*Received : Dec 9, 2021; Revised : Feb 1, 2021; Accepted : Apr 20, 2021*

*Reg 4-5 Med J 2021 ; 40(3) : 381–88.*

## บทนำ

กระดูกสะโพกหัก (fracture neck of femur) เป็นภาวะที่พบได้บ่อยในผู้สูงอายุ การรักษาด้วยการผ่าตัดเปลี่ยนข้อสะโพกเทียมเป็นการวิธีการรักษาที่เป็นวิธีมาตรฐานและเป็นการผ่าตัดใหญ่ ซึ่งต้องอาศัยความร่วมมือของสหสาขาวิชาเพื่อให้ผลการรักษาที่ดีทั้งก่อนและหลังผ่าตัด ในการผ่าตัดข้อสะโพกเทียมนั้น ผู้ป่วยบางราย อาจจะต้องได้รับเลือดเพิ่มเติม ซึ่งปัจจัยที่จะได้รับเลือดในผู้ป่วยอาจจะมียปัจจัย บางปัจจัยสามารถแก้ไขได้ บางปัจจัยไม่สามารถแก้ไขได้ ผู้นิพนธ์ได้ทำการศึกษาปัจจัยเสี่ยงที่จะต้องได้รับเลือดในผู้ป่วยที่รับการผ่าตัดข้อสะโพกเทียม เพื่อหาปัจจัยเสี่ยงที่สำคัญ ถ้าปัจจัยเสี่ยงนั้นสามารถหลีกเลี่ยงได้ จะทำให้ลดโอกาสการให้เลือดในผู้ป่วยได้ เพราะการให้เลือดก็มีข้อเสียจากการให้เลือดได้ เช่น acute transfusion reaction, wound infection<sup>1-3</sup>

จากการเก็บข้อมูลของโรงพยาบาลสมุทรสาคร คนไข้ที่ได้รับการผ่าตัดเปลี่ยนข้อสะโพกเทียมจากกระดูกสะโพกหัก ในช่วง มกราคม 2558 - ธันวาคม 2563 จำนวน 232 คน พบว่ามีผู้ได้รับเลือด 112 คน มีการจองเลือดไป 481 ยูนิต แต่มีการใช้เลือดไปเพียง 143 ยูนิต ซึ่งเลือดที่จองไว้ ถึงจะไม่ได้ใช้ แต่ยังต้องเสียค่าใช้จ่ายในการ crossmatch อยู่ดี ประมาณค่าใช้จ่ายยูนิตละประมาณ 300 บาท ซึ่งแปลว่าต้องเสียค่าใช้จ่าย

ในการจองเลือดประมาณ 100,000 บาท ต่อ 5 ปี ถ้าเราสามารถลดอัตราการจองเลือดที่เกิดความจำเป็นไปได้ การลดการจองเลือดที่ไม่ได้นำมาใช้จริงลง น่าจะสามารถลดค่าใช้จ่ายของโรงพยาบาลลงได้ โดยเฉพาะแต่การผ่าตัดข้อสะโพกเทียมเท่านั้น

ปัจจุบันได้มีการนำ A.I. (artificial intelligence) มาใช้ในวงการต่างๆ อย่างแพร่หลายมากขึ้น รวมทั้งมีการพัฒนาทางด้าน A.I. อย่างมาก machine learning เป็นสาขาหนึ่งของ A.I. ที่ได้มีการพัฒนามาก และเริ่มมีการนำมาใช้ในวงการแพทย์มากขึ้นเรื่อยๆ เช่น ใช้ในการช่วยประเมินปัจจัยเสี่ยง<sup>4-5</sup> ซึ่งมีหลายงานวิจัยพบว่า การใช้ machine learning มาช่วยในการประเมินปัจจัยเสี่ยงมีความแม่นยำมากกว่าการใช้วิธีประเมินปัจจัยเสี่ยงทางวิธีการทางสถิติทั่วไป<sup>6</sup>

## วัตถุประสงค์

1. เพื่อศึกษาปัจจัยเสี่ยงต่อการให้เลือดในผู้ป่วยสะโพกหักที่ได้รับการผ่าตัด hip arthroplasty ด้วยการ ใช้ machine learning
2. นำข้อมูลที่ได้มาสร้าง model เพื่อนำไปประเมินว่า ผู้ป่วยรายต่อไป ที่สะโพกหักและได้รับการผ่าตัดข้อสะโพกเทียมมีโอกาสจะต้องได้รับเลือดหลังผ่าตัดหรือไม่

## วิธีการศึกษา

ทำการศึกษาค้นคว้าโดย retrospective study จากเวชระเบียนผู้ป่วยที่ได้รับการวินิจฉัยเป็น fracture neck of femur ในช่วง มกราคม 255–ธันวาคม 2563 ได้จำนวนผู้ป่วย 232 คน

เกณฑ์ในการคัดเลือกเข้า (inclusion criteria) คือผู้ป่วย fracture neck of femur ที่ได้รับการผ่าตัดข้อสะโพกเทียม

เกณฑ์ในการคัดออก (exclusion criteria) คือ ผู้ป่วยที่เป็น pathologic fracture จาก tumor หรือ infection, ผู้ป่วยที่มี multiple fracture, ผู้ป่วยที่ไม่ได้รับการผ่าตัด, และผู้ป่วยที่ไม่สามารถหาข้อมูลทางเวชระเบียนได้ครบ

งานวิจัยนี้ได้รับอนุญาตจากคณะกรรมการในคน โรงพยาบาลสมุทรสาคร เลขที่ SKH REC 08/2564/V.1

ผู้วิจัยได้เก็บข้อมูล demographic data โดยเก็บข้อมูลของอายุ, เพศ, BMI, ASA, underlying disease เช่น HT, DM, MI, CVA, CKD (eGFR <40), pre-op hemoglobin, pre-op hematocrit, Garden classification และ เก็บข้อมูล perioperative และ post-operative data คือ pre-operative tranexamic acid, type of anesthesia,

operative time, intraoperative blood loss, type of prosthesis (bipolar/ THA, cemented, cementless), post-operative anticoagulation, post-operative tranexamic acid, post-operative NSAIDs, length of stay จากเวชระเบียน

เกณฑ์ในการให้เลือด คือ ผู้ป่วยที่มี hematocrit ต่ำกว่า 30% หรือต่ำกว่า 25% ในรายที่เป็น chronic anemia

## การวิเคราะห์ทางสถิติ

ผู้วิจัยใช้ chi-square test, ranksum, independent t test, Fisher exact test (R Foundation for statistical computing, Vienna, Austria) ในการประเมิน demographic data ดังตารางที่ 1 ส่วนข้อมูล perioperative, post-operative ดังตารางที่ 2 และ multivariate logistic regression ดังตารางที่ 3 เพื่อหา risk factors ผู้วิจัยใช้ machine learning ในการเลือก feature ที่มีความสัมพันธ์กับ transfusion โดยใช้ RFE (recursive feature elimination) algorithm เพื่อกำจัด feature ที่ไม่มีความสัมพันธ์กับ transfusion ออกไปแล้วนำ feature ที่มีความสัมพันธ์กับ transfusion มาสร้าง model โดยใช้ machine learning โดย library scikit learn

ตารางที่ 1 แสดง demographic data

| Factor                         | Total<br>(n = 232) | Transfusion<br>(n = 88) | Nontransfusion<br>(n = 144) | P value |
|--------------------------------|--------------------|-------------------------|-----------------------------|---------|
| <b>Gender*</b>                 |                    |                         |                             | .03     |
| Male                           | 78 (100)           | 57 (73.1)               | 21 (26.9)                   |         |
| Female                         | 154 (100)          | 31 (20.1)               | 123 (79.9)                  |         |
| <b>Age (yr)†median (range)</b> | 75 (40,94)         | 73 (41,88)              | 75 (57,89)                  | .59     |
| <b>BMI (kg/m2)‡mean (SD)</b>   | 23.9 (3.7)         | 21.02 (3.5)             | 25.32 (3.6)                 | .28     |
| <b>ASA*</b>                    |                    |                         |                             | .009    |
| II                             | 31 (100)           | 0 (0)                   | 31 (100)                    |         |
| III                            | 195 (100)          | 85 (43.6)               | 110 (56.4)                  |         |
| IV                             | 6 (100)            | 3 (33.3)                | 3 (66.7)                    |         |

\* chi-square, † Ranksum, ‡ independent t test, § Fischer exact test, แสดงค่าเป็นจำนวน (ร้อยละ) ยกเว้นระบุเป็นอย่างอื่น

ตารางที่ 1 แสดง demographic data (ต่อ)

| Factor                                 | Total<br>(n = 232) | Transfusion<br>(n = 88) | Nontransfusion<br>(n = 144) | P value |
|----------------------------------------|--------------------|-------------------------|-----------------------------|---------|
| <b>Co-morbidity*</b>                   |                    |                         |                             |         |
| DM                                     | 41 (100)           | 17 (41.5)               | 24 (58.5)                   | .77     |
| HT                                     | 131 (100)          | 52 (40)                 | 79 (60)                     | .24     |
| CKD                                    | 40 (100)           | 35 (88.5)               | 5 (12.5)                    | .03     |
| MI                                     | 13 (100)           | 6 (46.2)                | 7 (53.8)                    | .27     |
| CVA                                    | 14 (100)           | 8 (57.1)                | 6 (42.9)                    | .43     |
| Hb±, mean (SD)                         | 11.94 (1.7)        | 11.01 (1.6)             | 12.4 (1.6)                  | .001*   |
| Hct±, mean (SD)                        | 35.78 (4.3)        | 33.02 (4.1)             | 37.13 (4.2)                 | .001*   |
| <b>Garden Classification§</b>          |                    |                         |                             | .43     |
| I                                      | 0 (0)              | 0 (0)                   | 0 (0)                       |         |
| II                                     | 49 (100)           | 10 (20.4)               | 39 (80.9)                   |         |
| III                                    | 162 (100)          | 71 (48.1)               | 91 (51.9)                   |         |
| IV                                     | 21 (100)           | 6 (28.6)                | 15 (71.4)                   |         |
| <b>Duration (day)†, median (range)</b> | 3 (1,15)           | 3 (1,15)                | 3 (1,9)                     | .089    |

\* chi-square, † Ranksum, ± independent t test, § Fischer exact test, แสดงค่าเป็นจำนวน (ร้อยละ) ยกเว้นระบุเป็นอย่างอื่น

ตารางที่ 2 ข้อมูลส่วน perioperative, และ postoperative

| Factor                                                   | Total<br>(n = 232) | Transfusion<br>(n = 88) | Nontransfusion<br>(n = 144) | P value |
|----------------------------------------------------------|--------------------|-------------------------|-----------------------------|---------|
| <b>Type of anesthesia*</b>                               |                    |                         |                             | .17     |
| GA                                                       | 93 (100)           | 50 (53.7)               | 43 (46.3)                   |         |
| SB                                                       | 139 (100)          | 38 (27.3)               | 101 (72.7)                  |         |
| <b>Operative time (min)†<br/>median (range)</b>          | 60 (25,140)        | 55 (25,105)             | 55 (45,100)                 | .25     |
| <b>Intraoperative blood loss<br/>(cc)†median (range)</b> | 150 (20,900)       | 260 (30,700)            | 180 (20,800)                | .01*    |
| <b>Type of prosthesis*</b>                               |                    |                         |                             |         |
| Cemented bipolar                                         | 46 (100)           | 40 (86.9)               | 6 (13.1)                    | .0001*  |
| Cementless bipolar                                       | 168 (100)          | 40 (24.8)               | 128 (75.2)                  | .058*   |
| Cementless THA                                           | 18 (100)           | 8 (44.5)                | 10 (55.5)                   | .44     |
| <b>Postoperative anticoagulant*</b>                      | 79 (100)           | 36 (45.6)               | 43 (54.4)                   | .31     |
| <b>Transamine used*</b>                                  | 31 (100)           | 6 (19.4)                | 25 (80.6)                   | .53     |
| <b>Postoperative NSAIDs*</b>                             | 106 (100)          | 33 (31.1)               | 73 (68.9)                   | .42     |
| <b>Length of stay†median (range)</b>                     | 8 (5,72)           | 7 (7,63)                | 7 (5,43)                    | .10     |

\* chi-square, † Ranksum, ± Independent t test, § Fischer exact test, แสดงค่าเป็นจำนวน (ร้อยละ) ยกเว้นระบุเป็นอย่างอื่น

ตารางที่ 3 Multivariate logistic regression

| Factor                       | OR   | 95%CI      | P value |
|------------------------------|------|------------|---------|
| <b>Gender</b>                |      |            |         |
| Male                         | 1.98 | 1.12–2.74  | .02*    |
| Femle                        | 0.87 | 0.78–1.26  | .52     |
| <b>Age</b>                   | 0.99 | 0.67–1.96  | .2      |
| <b>BMI</b>                   | 0.96 | 0.94–1.23  | .1      |
| <b>ASA</b>                   | 0.80 | 0.69–0.93  | .6      |
| <b>Underlying disease</b>    |      |            |         |
| DM                           | 1.05 | 0.46–1.36  | .920    |
| HT                           | 0.89 | 0.85–2.36  | .64     |
| MI                           | 1.12 | 0.091–1.31 | .052    |
| CKD                          | 3.67 | 3.40–7.50  | .022*   |
| CVA                          | 0.86 | 0.64–2.15  | .748    |
| Hb (Pre-op)                  | 1.14 | 0.84–1.23  | .25     |
| <b>Type of Anesthesia</b>    |      |            |         |
| GA                           | 0.83 | 0.41–1.65  | .602    |
| SB                           | 0.33 | 0.87–2.62  | .31     |
| <b>Type of prosthesis</b>    |      |            |         |
| Cemented bipolar             | 2.1  | 1.58–2.63  | .03*    |
| Cementless bipolar           | 0.48 | 0.29–2.13  | .20     |
| Cementless THA               | 1.01 | 0.41–3.82  | .38     |
| <b>Transamine used</b>       |      |            |         |
| Pre-op                       | 0.58 | 0.34–2.98  | .053    |
| Post-op                      | 0.27 | 0.03–2.47  | .25     |
| <b>Post-op anticoagulant</b> | 0.53 | 0.84–1.55  | .35     |
| <b>Post-op NSAIDs</b>        | 0.51 | 0.20–1.27  | .15     |
| <b>Length of stay</b>        | 0.98 | 0.96–1.13  | .29     |

\* chi-square, † Ranksum, ‡ independent t test, § Fischer exact test

### ผลการศึกษา

จากการศึกษาพบว่า demographic data พบว่า ผู้ป่วยที่ได้รับเลือดเป็นกลุ่มที่เป็นเพศชาย, CKD เป็นส่วนใหญ่ และมีระดับ hemoglobin และ hematocrit ที่ต่ำกว่าอีกกลุ่ม

จากข้อมูลในส่วน perioperative และ postoperative พบว่า การใส่ prosthesis ชนิด

cemented มี intraoperative blood loss ที่มากกว่า และมีโอกาสได้รับเลือดมากกว่า

จาก multivariate analysis พบว่า เพศชาย, โรคไต, prosthesis ชนิด cemented เพิ่มความเสี่ยงต่อการให้เลือดอย่างมีนัยสำคัญ

จากการนำข้อมูลทั้งหมดมาใช้ machine learning โดยใช้ RFE เลือก feature ที่สำคัญออกมา


พบว่า มีเพศชาย (male), โรคไต (CKD), โรคหัวใจขาดเลือด (MI), ชนิดของ prosthesis แบบใช้ cement (cemented), ASA เป็น feature ที่สามารถเป็นตัวแทนของข้อมูลทั้งหมดได้ หลังจากนั้นจึงนำ feature ดังกล่าวมาสร้าง model โดยใช้ random forest classifier (คือการนำ decision tree หลายๆอันมาทำนายแล้วเลือกว่าส่วนใหญ่ของ decision tree เลือก class ไหน (ให้เลือดหรือไม่ให้เลือด) พบว่ามี accuracy ร้อยละ 80

นำมา plot ROC curve (receiver operating characteristic curve) ซึ่งเป็นกราฟที่ plot ระหว่าง true positive rate (แกนY) กับ false positive rate (แกนX) เป็นตัวชี้วัดว่า model นั้นสามารถแยกแยะ 2 กลุ่มออกจากกันได้ดีแค่ไหน ยิ่งกราฟอยู่เหนือจากเส้นประ มากเท่าไรแปลว่า model นี้แม่นยำมาก) ได้ดังรูปที่ 1, 2

```
[29] from sklearn.metrics import accuracy_score  
y_pred = model.predict(X_test)  
accuracy_score(y_test,y_pred)
```

0.8

รูปที่ 1 accuracy ของ model โดยใช้ random forest classifier = 80%



รูปที่ 2 ROC curve

การนำ model ไปพยากรณ์ คือ เอาข้อมูลของคนไข้ คือ เพศ (ชาย = 1, หญิง = 0), เป็นโรคไตหรือไม่ (เป็นโรคไต = 1, ไม่เป็นโรคไต = 0), เป็นโรคหัวใจขาดเลือดหรือไม่ (เป็นโรคหัวใจขาดเลือด = 1, ไม่เป็นโรคหัวใจขาดเลือด = 0), ชนิดของ prosthesis

(cemented = 1, cementless = 0), ASA (I = 1, II = 2, III = 3, IV = 4) ในมาใส่ใน model ที่ได้ (โดยใส่ข้อมูลเรียงตามนี้ เพศ, โรคไต, โรคหัวใจขาดเลือด, prostheses, ASA) แล้วให้ model พยากรณ์

จากการนำ model ไปใช้งานจริง ตัวอย่าง  
คือ ผู้ป่วยหญิง, อายุ 84 ปี, มีโรคประจำตัวคือ CKD,  
ใส่ prosthesis cemented ASA III จึงใส่ค่าใน model  
ไป 0 (เพศหญิง), 1 (มี CKD), 0 (ไม่มีโรคหัวใจขาดเลือด),

1 (ใส่ cemented prostheses), 3 (ASA=3) ตามลำดับ  
model ทำนายว่าได้รับเลือด ผู้ป่วยจริงได้รับเลือด  
เช่นกัน ตามรูปที่ 3

```
mydata=[[0,1,0,1,3]])  
array = model.predict(mydata)  
print('Patient need not tranfusion') if array[0] == 0 else print ('Patient may need transfusion')  
  
Patient may need transfusion
```

รูปที่ 3 แสดงการนำ model ไปใช้ทำนายการให้เลือด

อีกตัวอย่างคือ ผู้ป่วยหญิง, อายุ 70 ปี,  
มีโรคประจำตัวคือ HT, ใส่ prosthesis cemented,  
ASA III จึงใส่ค่าใน model ไป 0 (เพศหญิง), 0 (ไม่มี

CKD), 0 (ไม่มีโรคหัวใจขาดเลือด), 1 (ใส่ cemented  
prostheses), 3 (ASA=3) ตามลำดับ model ทำนายว่า  
ไม่ได้รับเลือด ผู้ป่วยจริงไม่ได้รับเลือด ตามรูปที่ 4

```
mydata=[[0,0,0,1,3]])  
array = model.predict(mydata)  
print('Patient need not tranfusion') if array[0] == 0 else print ('Patient may need transfusion')  
  
Patient need not tranfusion
```

รูปที่ 4 แสดงการนำ model ไปใช้ทำนายการให้เลือด

## วิจารณ์

ในการผ่าตัดข้อสะโพกเทียมผู้ป่วยบางรายอาจ  
จะต้องรับเลือดเลือดบ้าง ซึ่งการได้รับเลือดจากผู้อื่นก็  
มีข้อเสีย เช่น การเกิด acute reaction transfusion,  
fluid overload, เพิ่มระยะเวลาในการนอนโรงพยาบาล  
แต่การผ่าตัดข้อสะโพกเทียมนั้น ไม่ใช่ผู้ป่วยทุกคนที่จะ  
ต้องได้รับเลือด จากสถิติของโรงพยาบาลสมุทรสาคร  
พบว่า ความจริงแล้วผู้ได้รับเลือดประมาณ 1 ใน 3  
ของผู้ป่วยที่ได้รับการผ่าตัดข้อสะโพกเทียม แต่อย่างไร  
ก็ตามผู้ป่วยที่เข้ารับการผ่าตัดข้อสะโพกเทียมได้รับการ  
จองเลือดทุกราย ซึ่งมีค่าใช้จ่ายในการจองเลือดยูนิตละ  
140 บาท และถ้าผู้ป่วยต้องได้รับเลือดก็จะมีค่าใช้จ่าย  
จากการได้รับเลือด 1,700 บาทต่อยูนิต ถ้าเราสามารถ  
ลดโอกาสการให้เลือดแก่ผู้ป่วยได้โดยลดปัจจัยเสี่ยงที่  
สามารถแก้ไขได้ ภาวะแทรกซ้อนจากการได้รับเลือดก็น่า

จะลดลง และถ้าเราสามารถประเมินความเสี่ยงได้ผู้ป่วย  
รายใดมีความเสี่ยงต่ำ อาจจะไม่จำเป็นต้องจองเลือด  
หรือจองเลือดลดลงกว่าปกติ จะสามารถลดค่าใช้จ่ายที่  
ไม่จำเป็นให้โรงพยาบาลได้ เช่นถ้า model พยากรณ์ว่า  
คนไข้ที่จะรับการผ่าตัดไม่ต้องให้เลือด เราก็จะจองเลือด  
เพียง 1 ยูนิตจากปกติจะจอง 2 ยูนิต ก็จะสามารถลดค่าใช้จ่าย  
สำหรับการจองเลือดไปได้ 1 ยูนิต ถ้าจากการศึกษานี้  
จะสามารถลดการจองเลือดโดยไม่จำเป็นไป 154 ราย  
(ประมาณ 2/3 ของผู้ป่วยสะโพกหักทั้งหมด) คิดเป็นเงิน  
ประมาณ  $140 \times 154 = 21,560$  บาท

## สรุป

จากการศึกษานี้พบว่า ปัจจัยเสี่ยงต่อการ  
ได้รับเลือดในผู้ป่วยสะโพกหักที่ได้รับการผ่าตัดข้อ  
สะโพกเทียม คือ male, CKD, cemented prosthesis



ดังนั้นในผู้ป่วยที่มีความเสี่ยงดังกล่าว จึงควรแก้ไขก่อนผู้ป่วยได้รับผ่าตัด เช่น ผู้ป่วย CKD ควรให้ DDAVP ก่อนไปผ่าตัด, พยายามใช้ prosthesis ชนิด cementless และเราสามารถประเมินได้ว่า ผู้ป่วยรายใดอาจจะต้องได้รับการให้เลือดหลังผ่าตัดโดยใช้ model ที่สร้างขึ้นมา ซึ่งสามารถทำให้ลดภาวะแทรกซ้อนที่อาจเกิดจากการให้เลือดได้ ลดค่าใช้จ่ายจากการจองเลือดที่ไม่จำเป็นลงได้ และเราสามารถนำข้อมูลที่ได้ไปประยุกต์กับการผ่าตัดอื่นในโรงพยาบาลได้ ซึ่งจะสามารถช่วยประหยัดค่าใช้จ่ายในการจองเลือดได้อีกมาก

### เอกสารอ้างอิง

1. Taneja A, El-Bakoury A, Khong H, et al. Association between allogeneic blood transfusion and wound infection after total hip or knee arthroplasty: a retrospective case-control study. *J Bone Jt Infect.* 2019;4(2):99–105. doi: 10.7150/jbji.30636.
2. Shaw RE, Johnson CK, Ferrari G, et al. Balancing the benefits and risks of blood transfusions in patients undergoing cardiac surgery: a propensity-matched analysis. *Interact Cardiovasc Thorac Surg.* 2013;17(1):96–102. doi: 10.1093/icvts/ivt124.
3. Kesler KK, Brown TS, Martin JR, et al. Risk Factors for Blood Transfusion After Primary Total Hip Arthroplasty. *Reconstructive Review.* 2009;9:49–53
4. Smita J, Seema V, Rajesh K. Risk factors, susceptibility, and machine learning techniques for cancer prediction. *Drug intervention Today.* 2018;10(4):580–92.
5. Kwon O, Na W, Kim YH. Machine Learning: a New Opportunity for Risk Prediction. *Korean Circ J.* 2020;50(1):85–7. doi: 10.4070/kcj.2019.0314.
6. Florian H, Anastasia T, Paul H, et al. Machine Learning: An Approach in Identifying Risk Factors for Coercion Compared to Binary Logistic Regression. *Psychiatry.* 2018;9:258. doi: 10.3389/fpsy.2018.00258