



HỘI HÔ HẤP
THÀNH PHỐ HỒ CHÍ MINH

HỘI NGHỊ THƯỜNG NIÊN HỘI HÔ HẤP - HRS 2026
THE ANNUAL CONFERENCE OF THE HO CHI MINH RESPIRATORY SOCIETY

Trí tuệ nhân tạo & học máy trong bệnh lí hô hấp

PGs. Ts. Đỗ Văn Dũng
Giảng viên cao cấp

VŨNG TÀU, TP.HCM - NGÀY 21 THÁNG 3 NĂM 2026

NỘI DUNG CHÍNH

- 1 Ứng dụng Hiện tại của AI trong Hồ hấp**
- 2 Thách thức và Hạn chế**
- 3 Định hướng Tương lai cho Hội Hồ hấp TP HCM**

Bối cảnh và Tầm quan trọng

- **Bối cảnh thách thức trong Hồ hấp:**
 - Gia tăng gánh nặng bệnh tật (COPD, hen suyễn, ung thư phổi, COVID-19).
 - Nhu cầu cấp thiết về **chẩn đoán sớm, cá nhân hóa điều trị và quản lý bệnh mạn tính hiệu quả hơn.**
- **Vai trò của AI:** AI không chỉ là công cụ mà là "**người thay đổi cuộc chơi**" (**game-changer**), mang lại tốc độ, độ chính xác và khả năng phân tích dữ liệu khổng lồ mà con người không thể đạt được.

- Hand designed features:
Creatinine⁻¹, Lactate, log(WBC)

- Features:
Creatinine, Lactate, WBC

1. I. Goodfellow et al., *Deep learning*
(The MIT Press, Cambridge,
Massachusetts, 2016), *Adaptive
computation and machine learning*.

**HRS
2026**

Feature do thiết
kế bằng tay hay
do máy

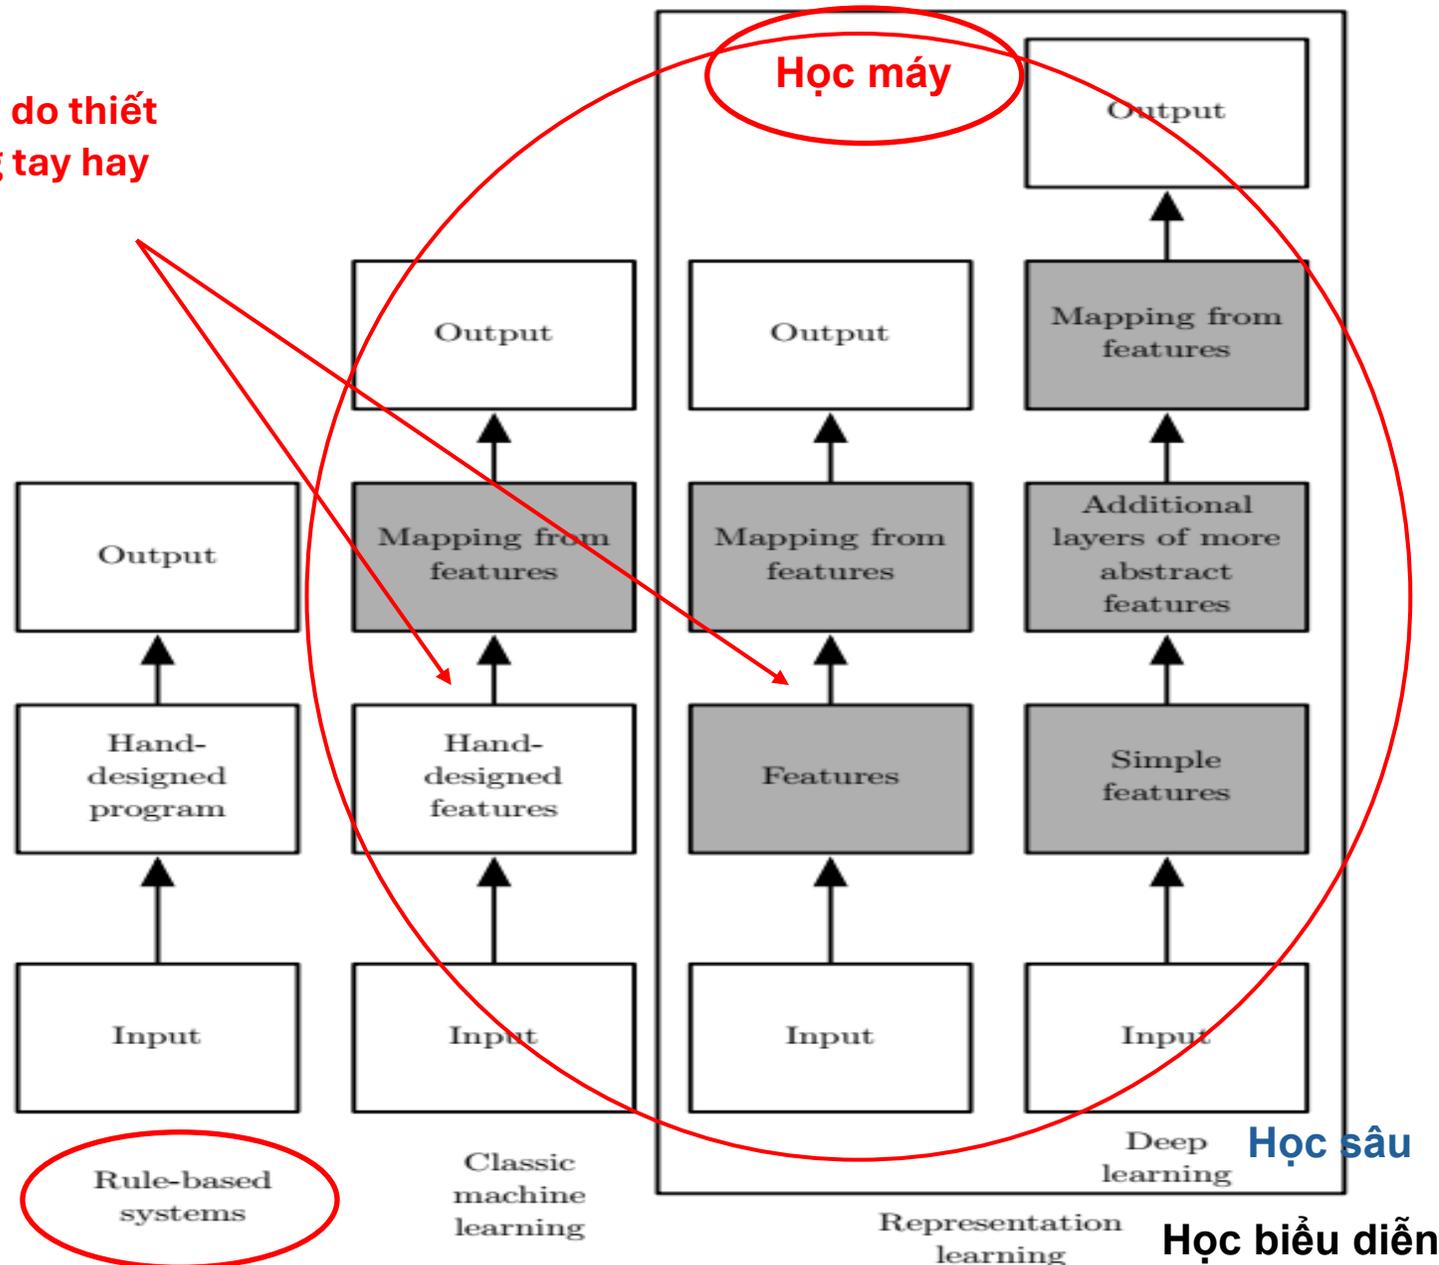


Figure 1.5: Flowcharts showing how the different parts of an AI system relate to each other within different AI disciplines. Shaded boxes indicate components that are able to learn from data.



Let's get in sync: current standing and future of AI-based detection of patient-ventilator asynchrony

Thijs P. Rietveld¹, Björn J. P. van der Ster¹, Abraham Schoe², Henrik Endeman^{1,3}, Anton Balakirev⁴, Daria Kozlova⁴, Diederik A. M. P. J. Gommers¹ and Annemijn H. Jonkman^{1*} 

Results Nineteen studies were identified. Multiple forms of AI have been used for the automated detection of PVA, including rule-based algorithms, machine learning and deep learning. Three licensed algorithms are currently reported. Results of algorithms are generally promising (average reported sensitivity, specificity and accuracy of 0.80, 0.93 and 0.92, respectively), but most algorithms are only available offline, can detect a small subset of PVAs (focusing mostly on ineffective effort and double trigger asynchronies), or remain in the development or validation stage (84% (16/19 of the reviewed studies)). Moreover, only in 58% (11/19) of the studies a reference method for monitor-

Rule-based algorithms

Rule-based algorithms are one of the earliest, simplest forms of AI and include manually determined rules and thresholds [26], based on expert knowledge/consensus [27]. These algorithms have seen widespread application in clinical monitoring software [28], likely due to their transparent and comprehensible nature.

Table 1 Characteristics of selected rule-based algorithms (studies are arranged chronologically)

Author	Type of PVA	Population	Input data	Algorithm
Rodriguez et al. [30]	Reverse trigger, double trigger	ARDS patients on volume-controlled ventilation	Paw and flow waveforms	Rule-based algorithm
Baedorf-Kassis et al. [29]	Reverse trigger	15 ARDS patients (23,321 breaths)	Flow, pressure, volume and Pes waveforms, Campbell diagrams (PV loops)	Rule-based software and modified ResNet network

- Hand designed features:
Creatinine⁻¹, Lactate, log(WBC)

- Features:
Creatinine, Lactate, WBC

Feature (biến độc lập) do thiết kế bằng tay hay do máy

1. I. Goodfellow et al., *Deep learning* (The MIT Press, Cambridge, Massachusetts, 2016), *Adaptive computation and machine learning*.

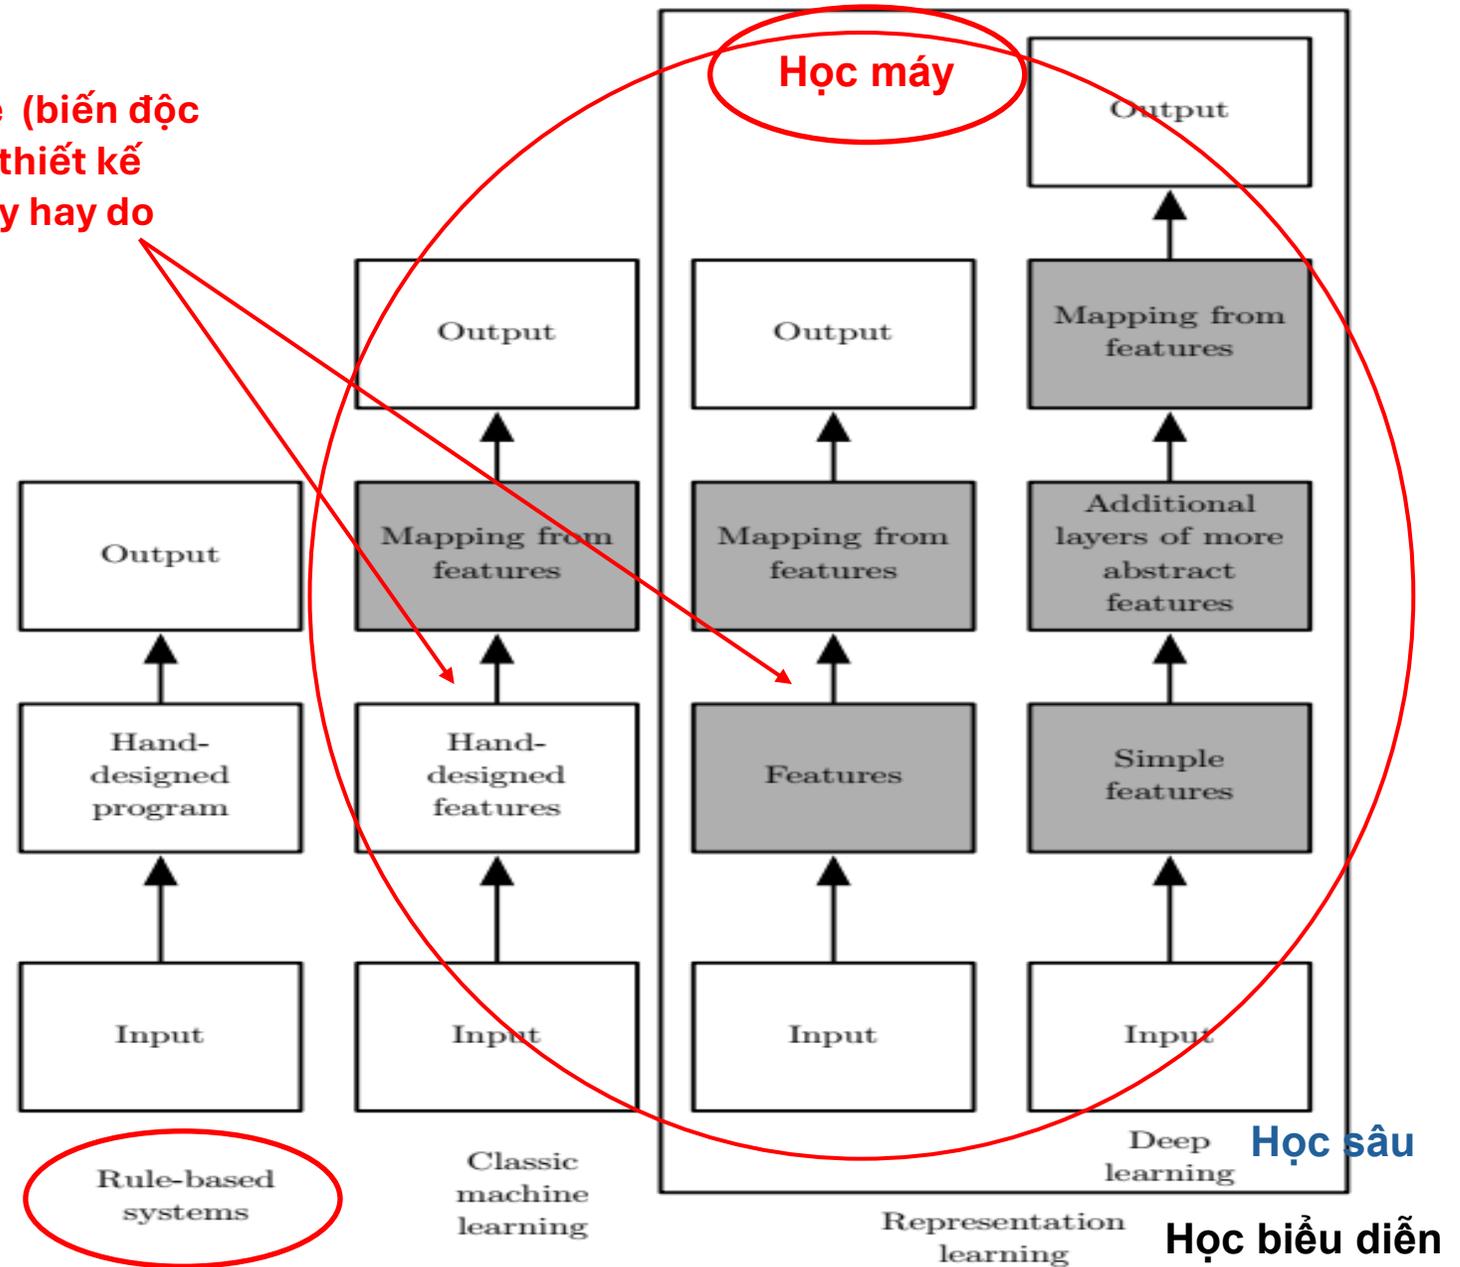


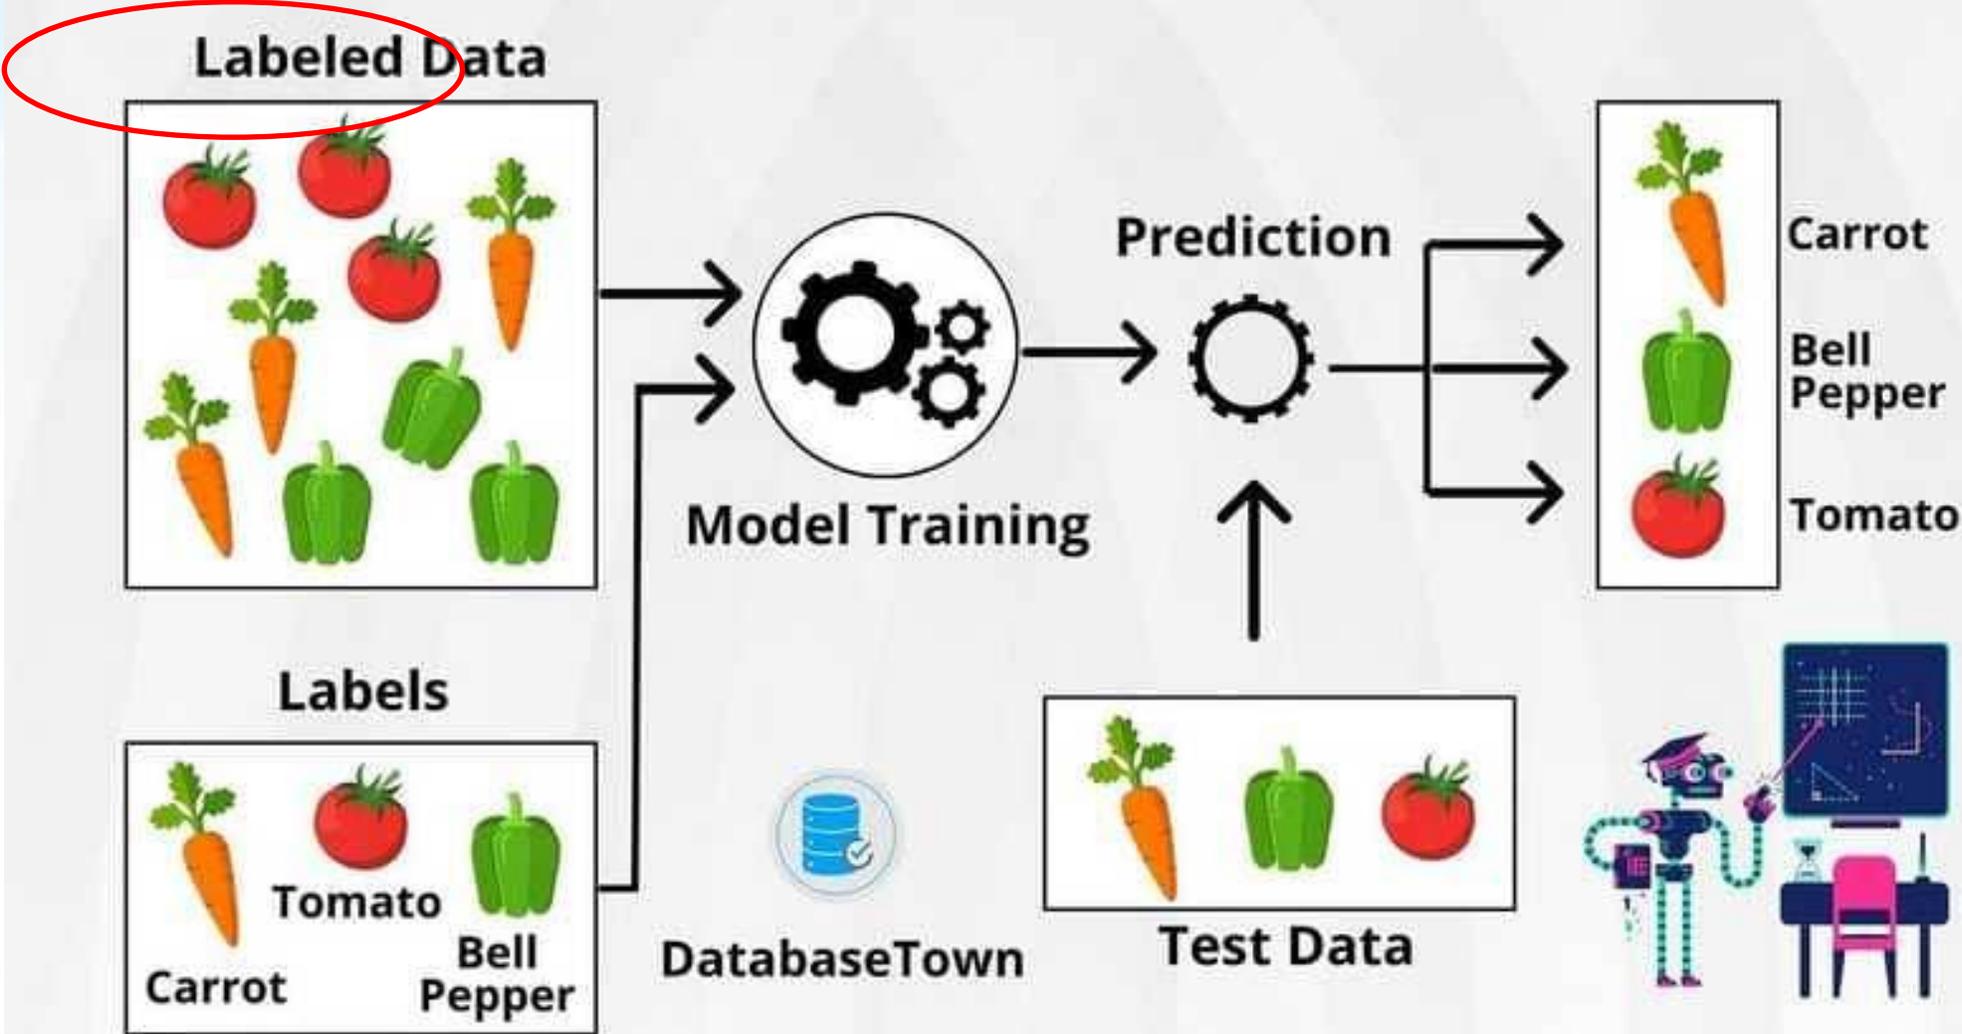
Figure 1.5: Flowcharts showing how the different parts of an AI system relate to each other within different AI disciplines. Shaded boxes indicate components that are able to learn from data.

Các loại học máy

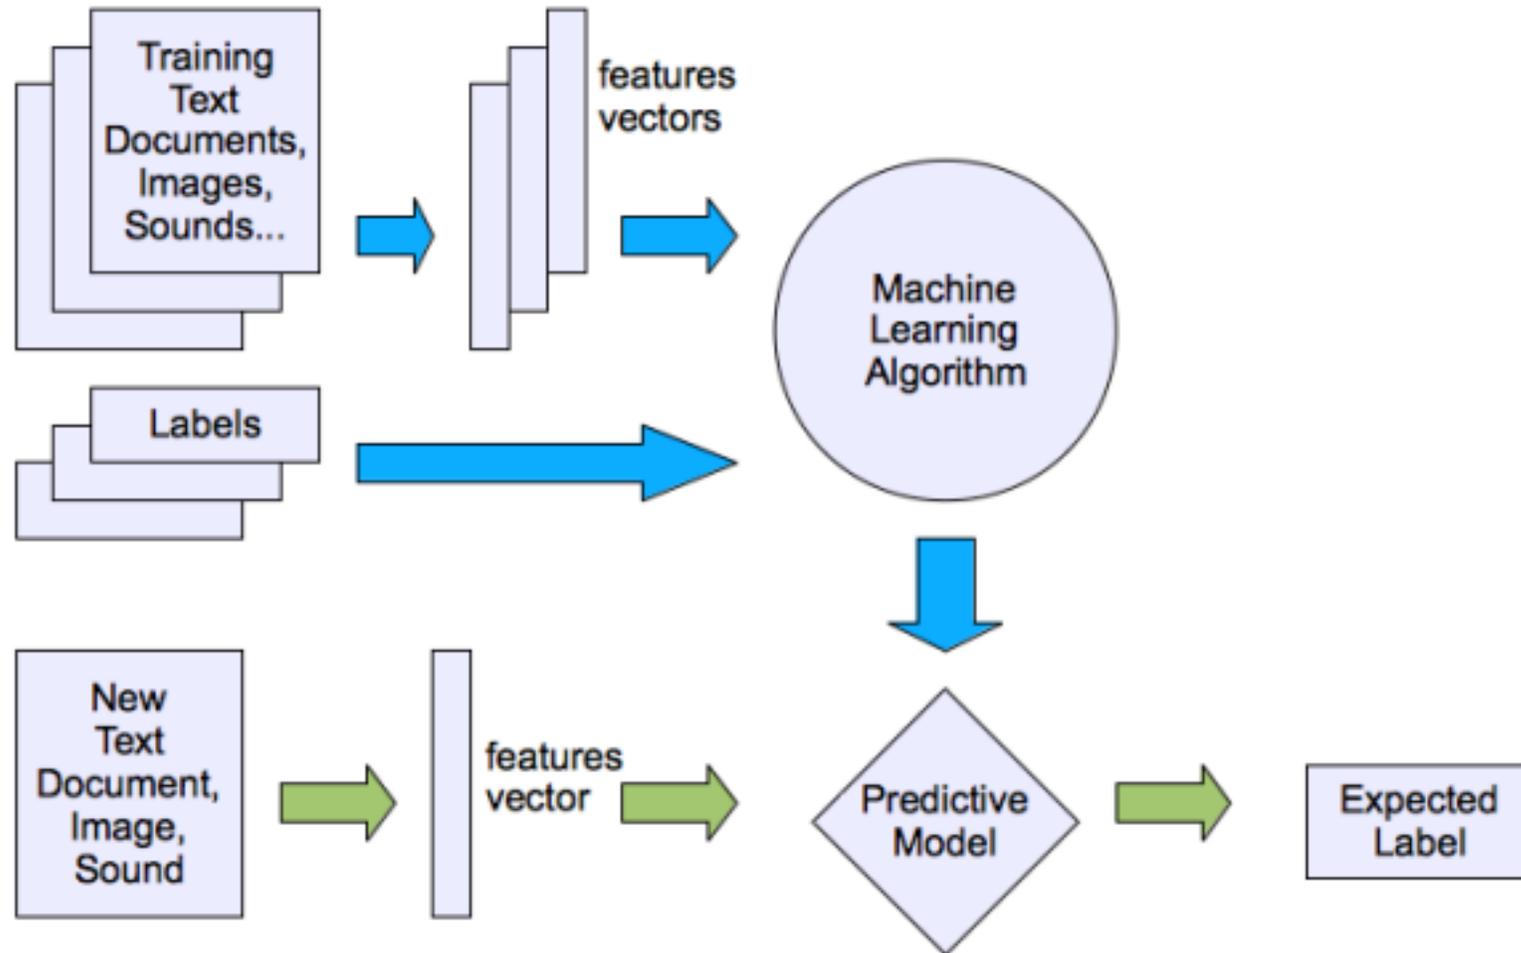
- Học máy có giám sát (Supervised)
 - – Đầu vào: dữ liệu huấn luyện + đầu ra mong muốn (nhãn)
- Học máy không giám sát (Unsupervised)
 - – Đầu vào: dữ liệu huấn luyện (không có đầu ra mong muốn)

SUPERVISED LEARNING

Supervised machine learning is a branch of artificial intelligence that focuses on training models to make predictions or decisions based on labeled training data.

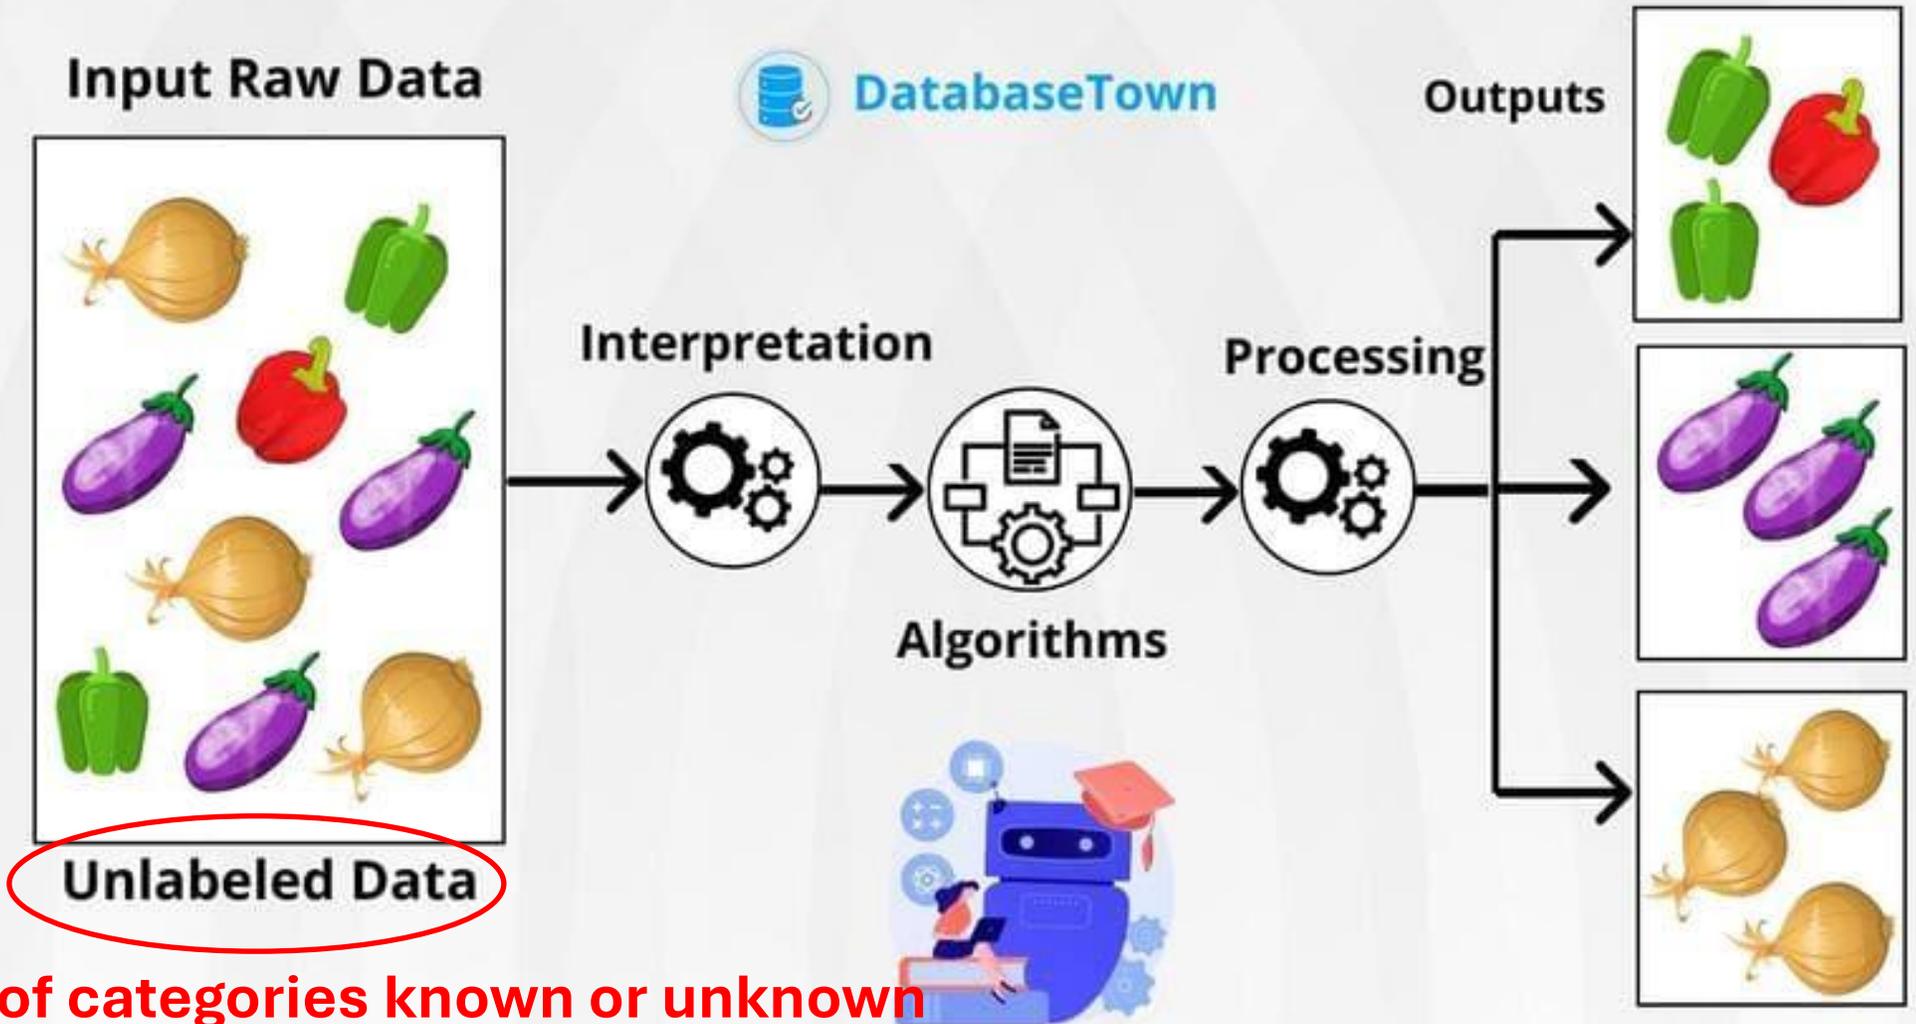


Học có giám sát

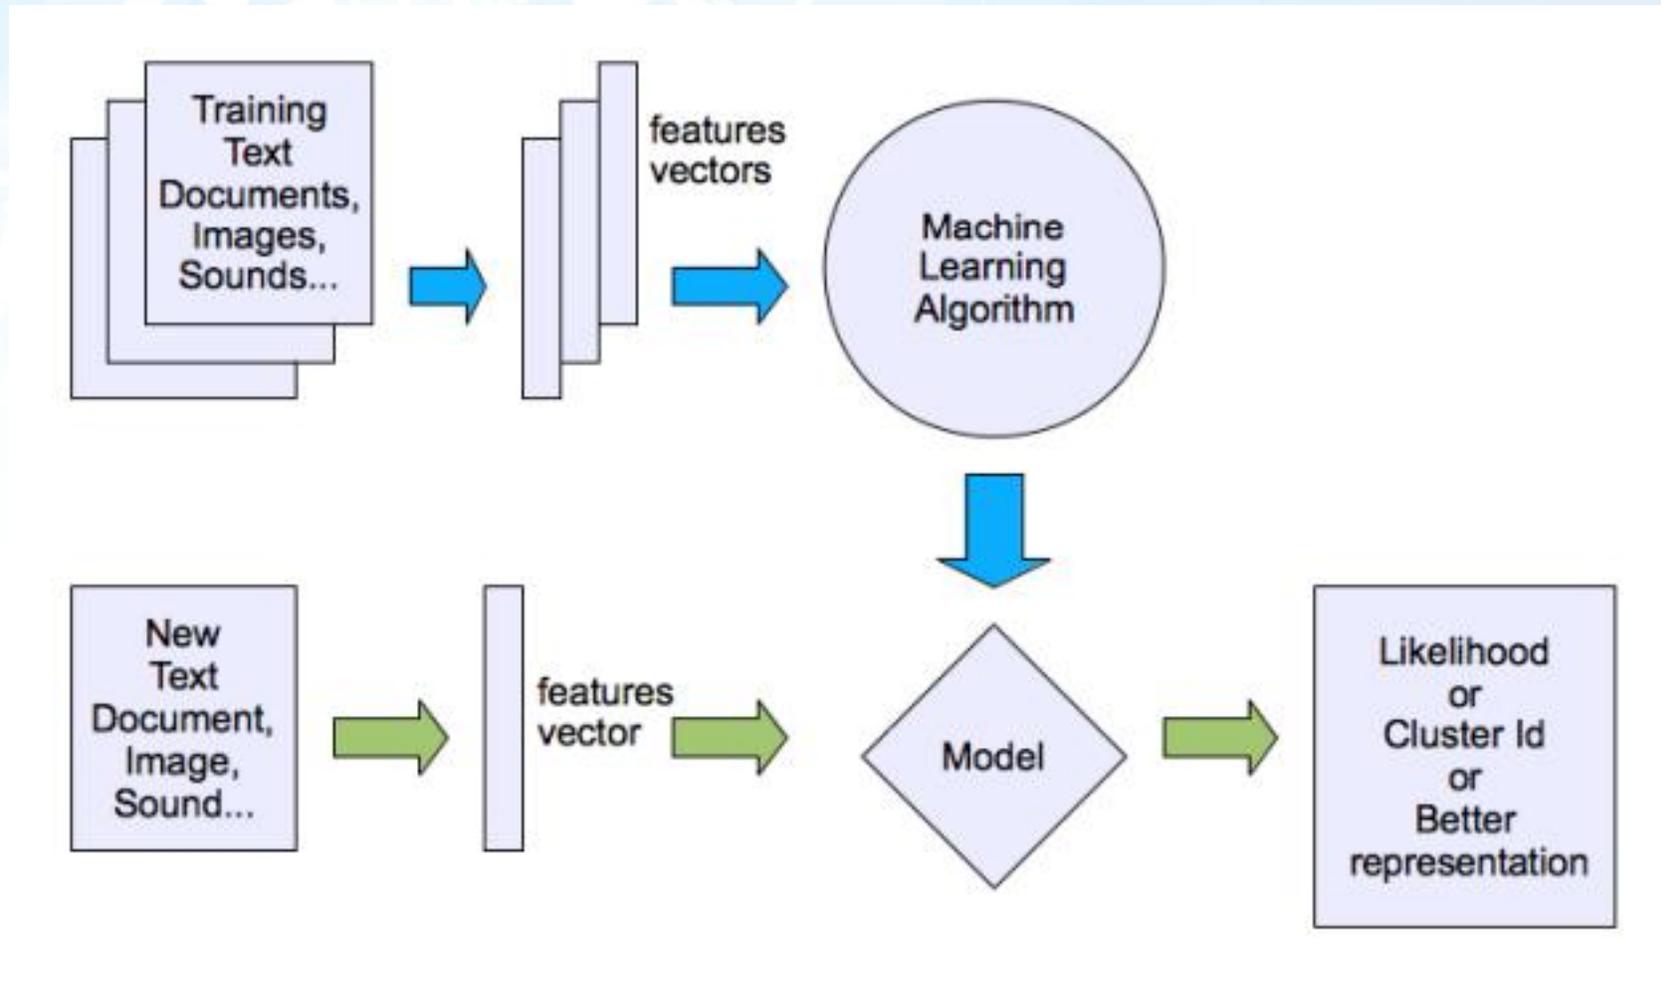


UNSUPERVISED LEARNING

Unsupervised learning is a type of machine learning where the algorithm learns from unlabeled data without any predefined outputs or target variables.

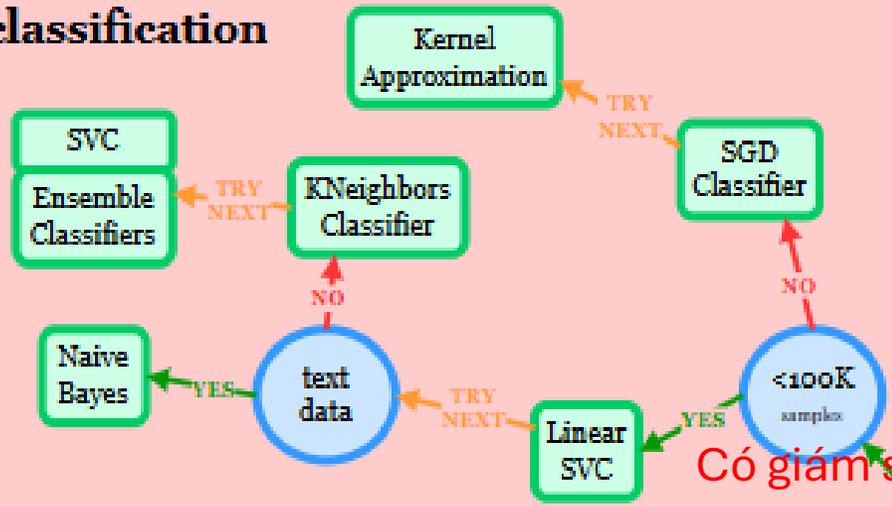


Học không giám sát



scikit-learn algorithm cheat sheet

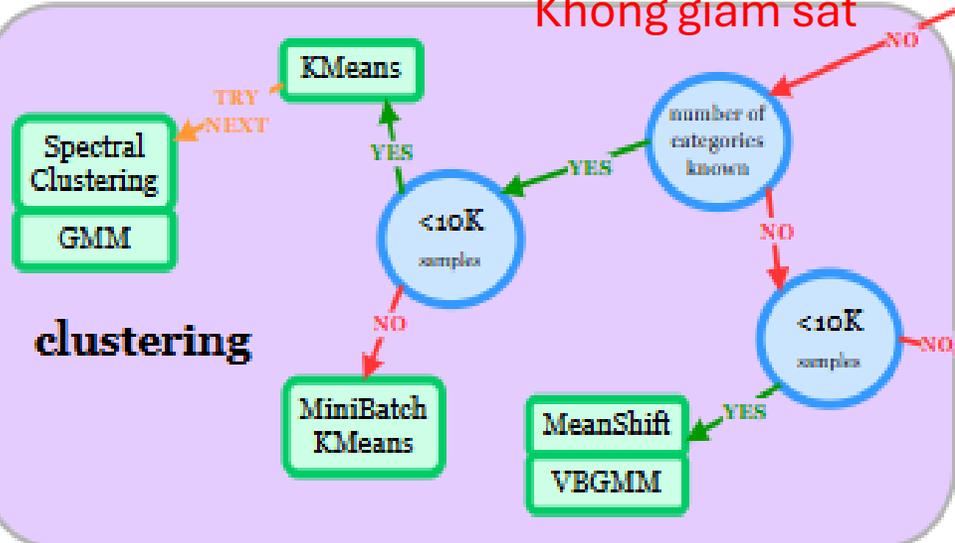
classification



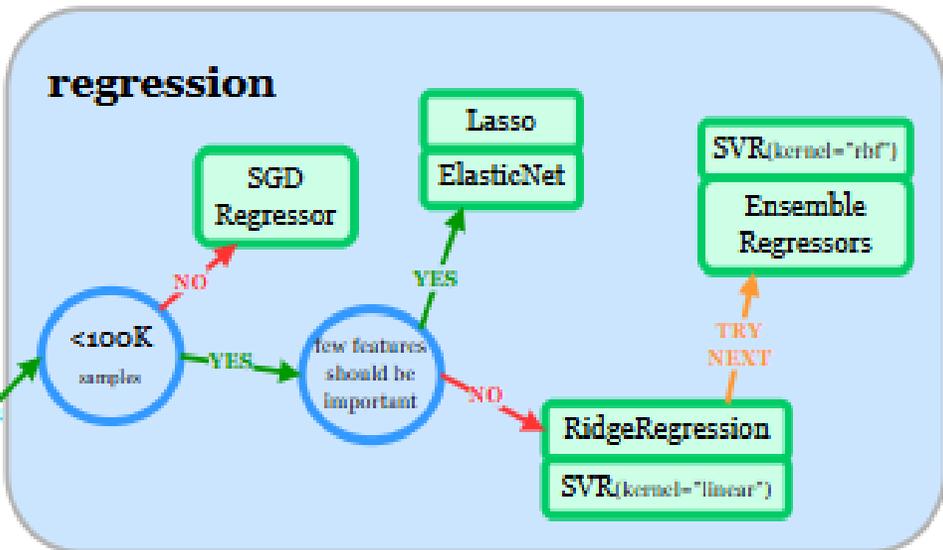
Có giám sát

Không giám sát

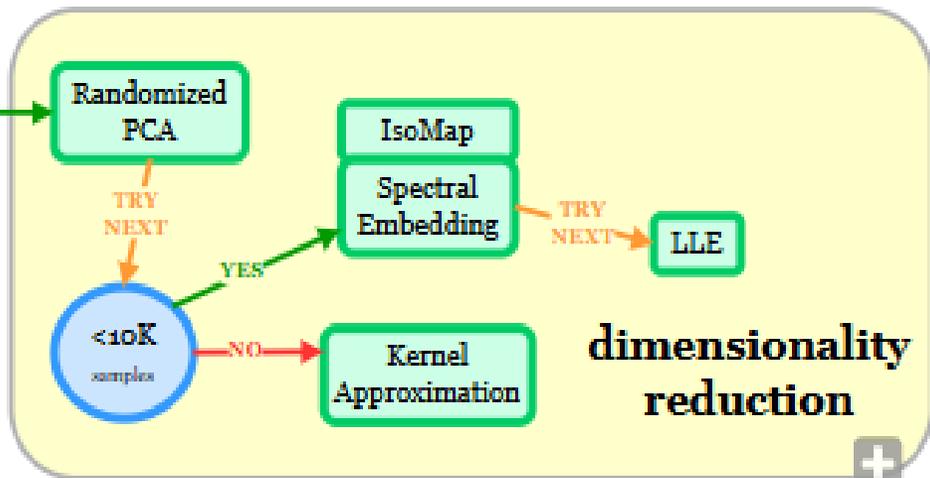
clustering

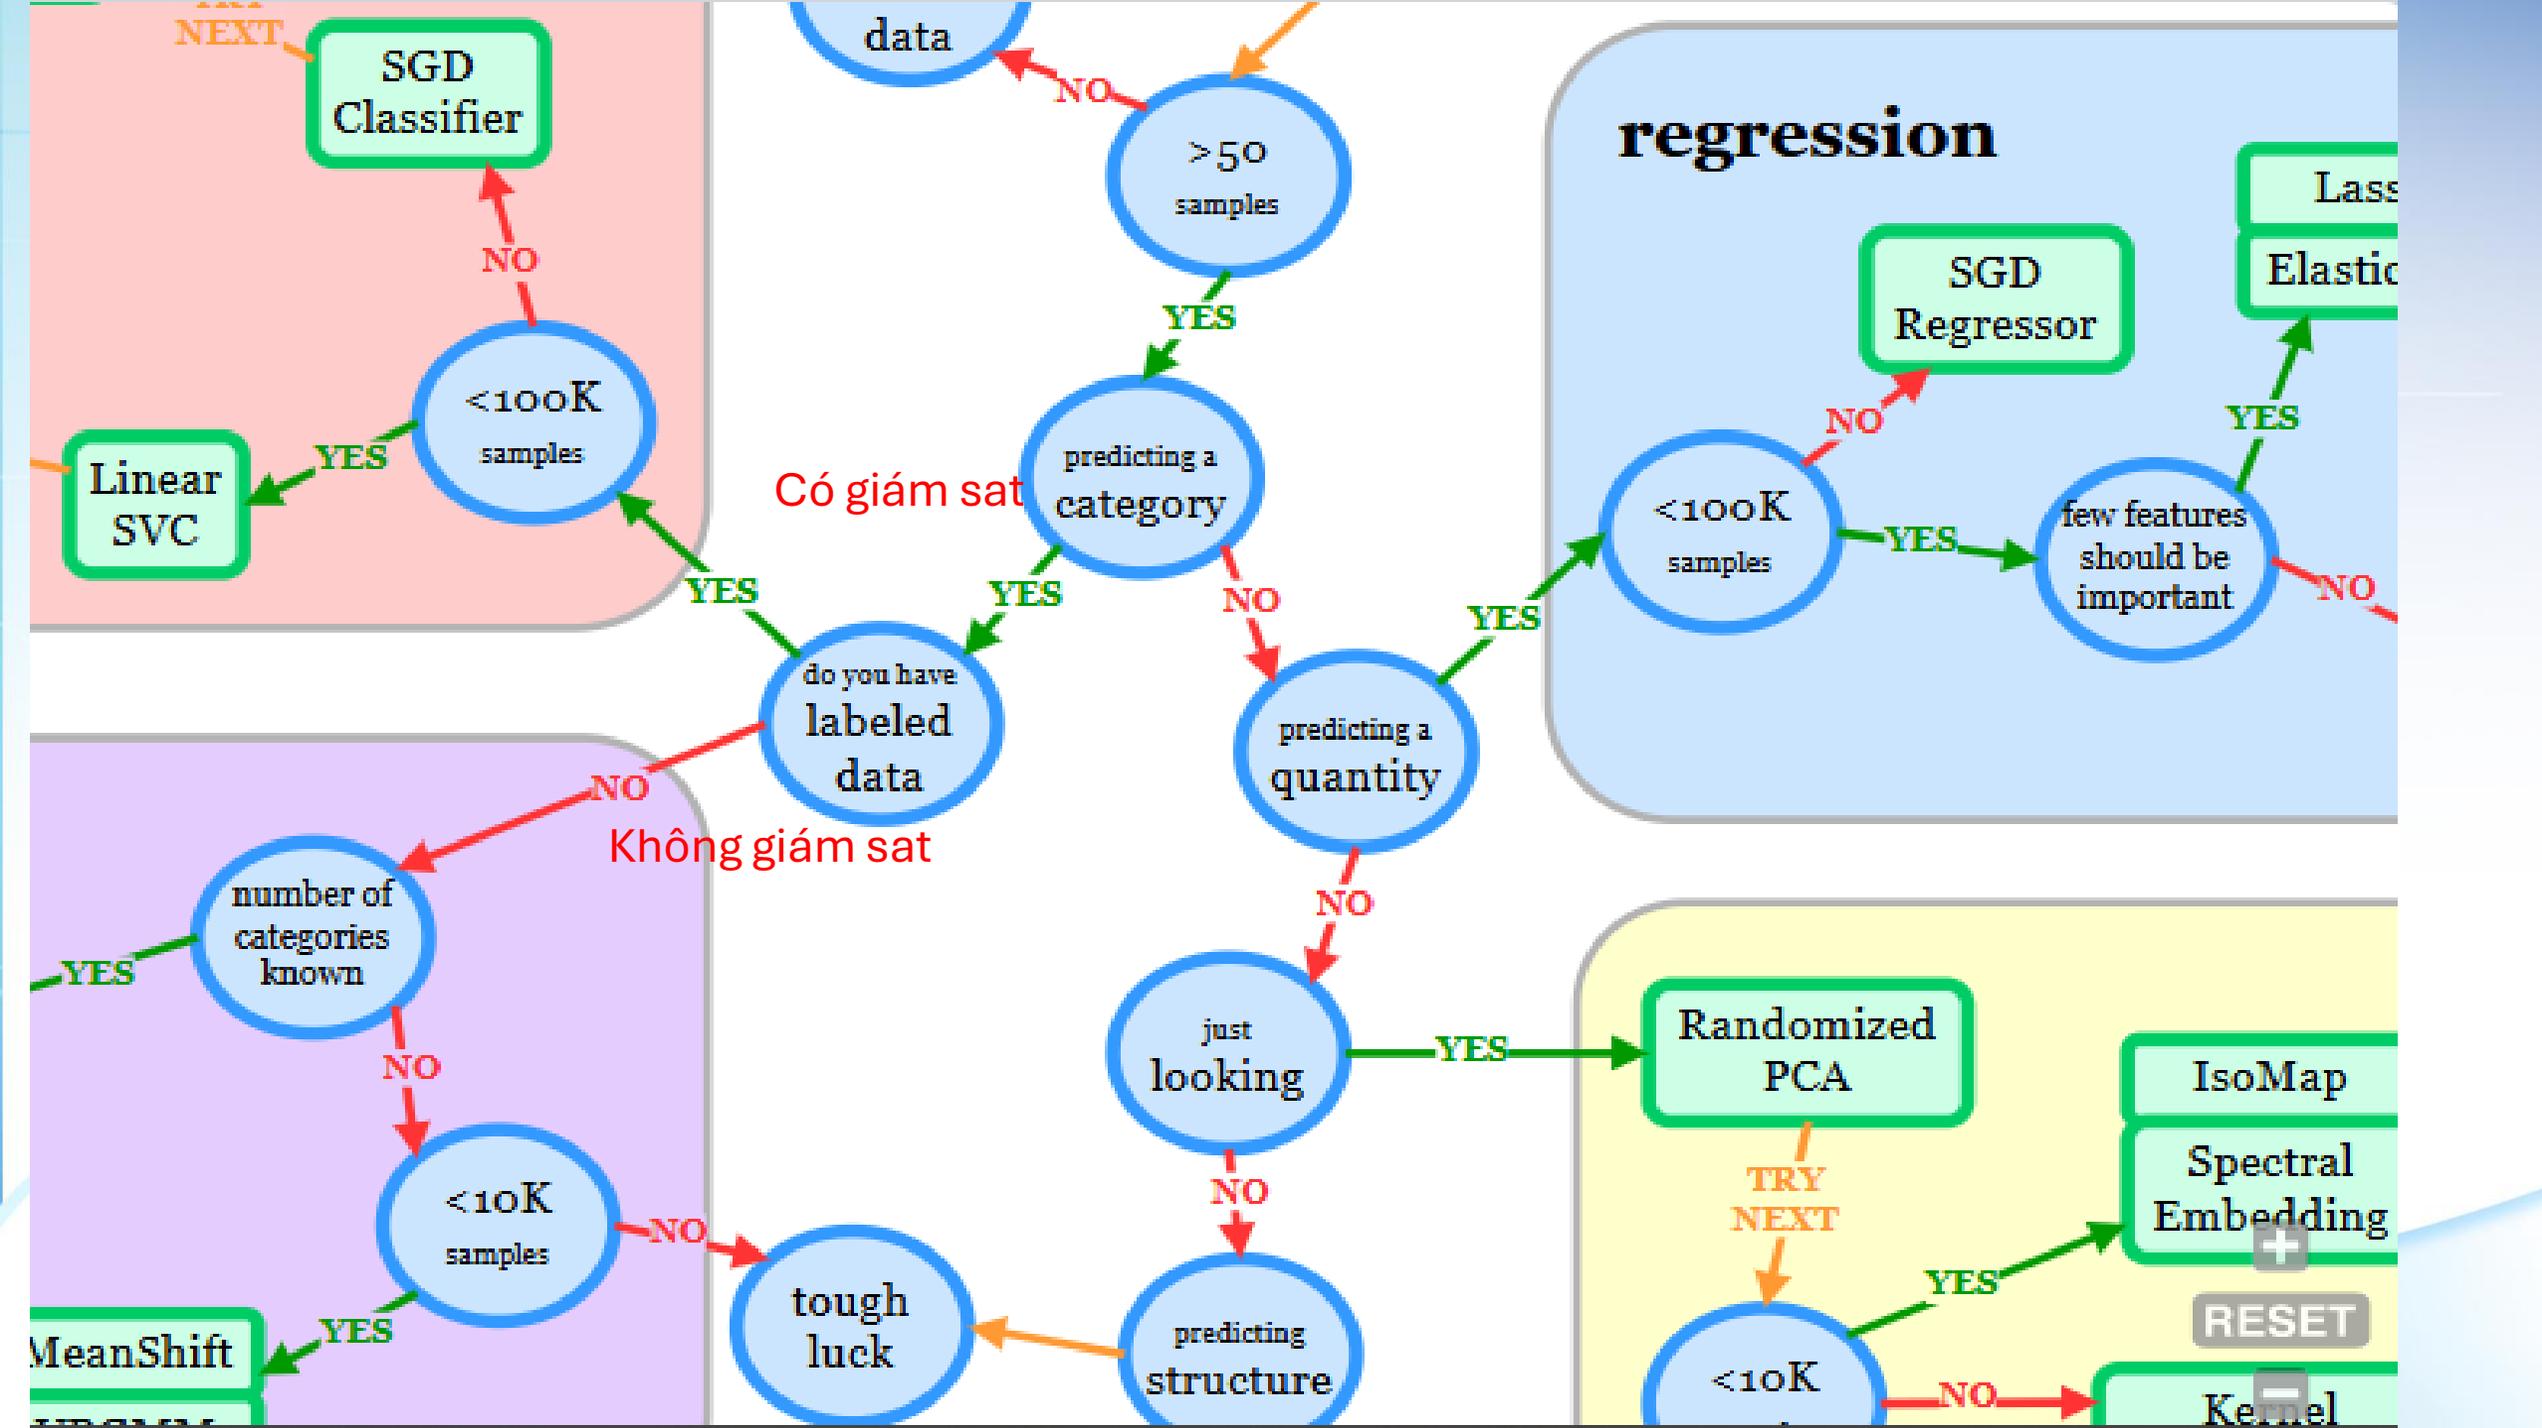


regression



dimensionality reduction





Feature (biến độc lập) do thiết kế bằng tay hay do máy

- Hand designed features: Creatinine⁻¹, Lactate, log(WBC)

- Features: Creatinine, Lactate, WBC

1. I. Goodfellow et al., *Deep learning* (The MIT Press, Cambridge, Massachusetts, 2016), *Adaptive computation and machine learning*.

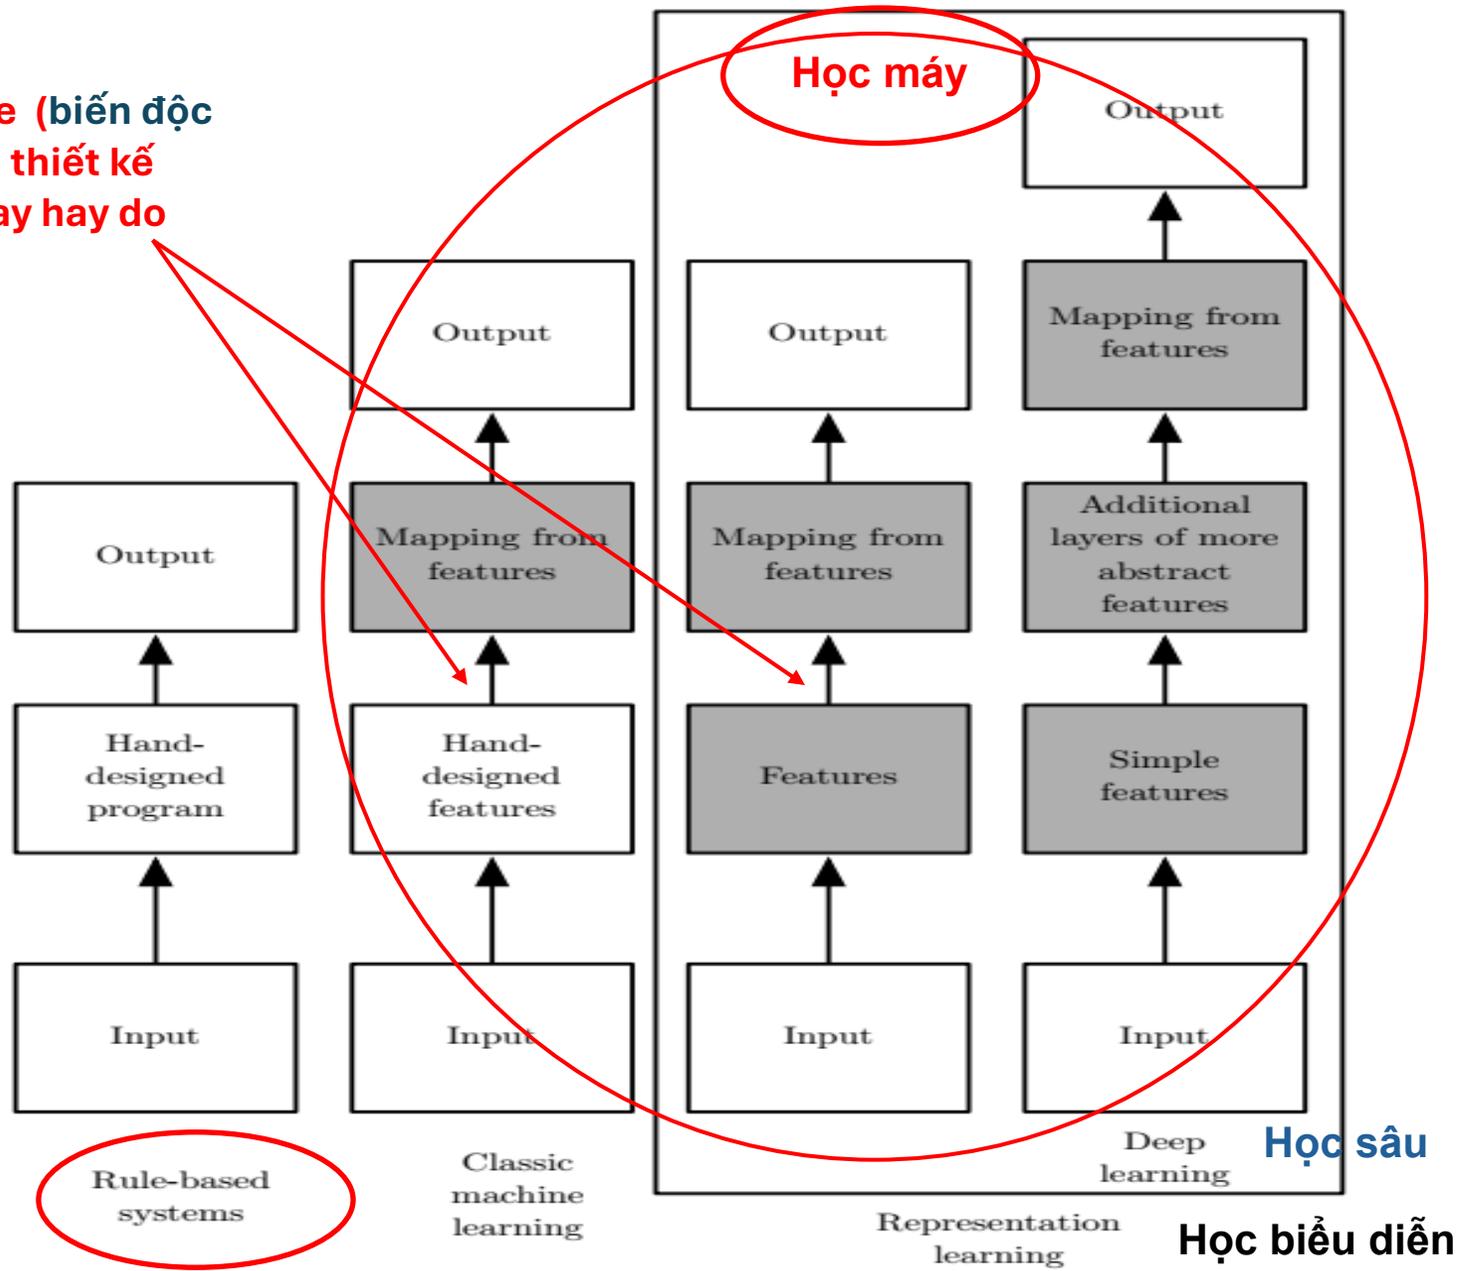
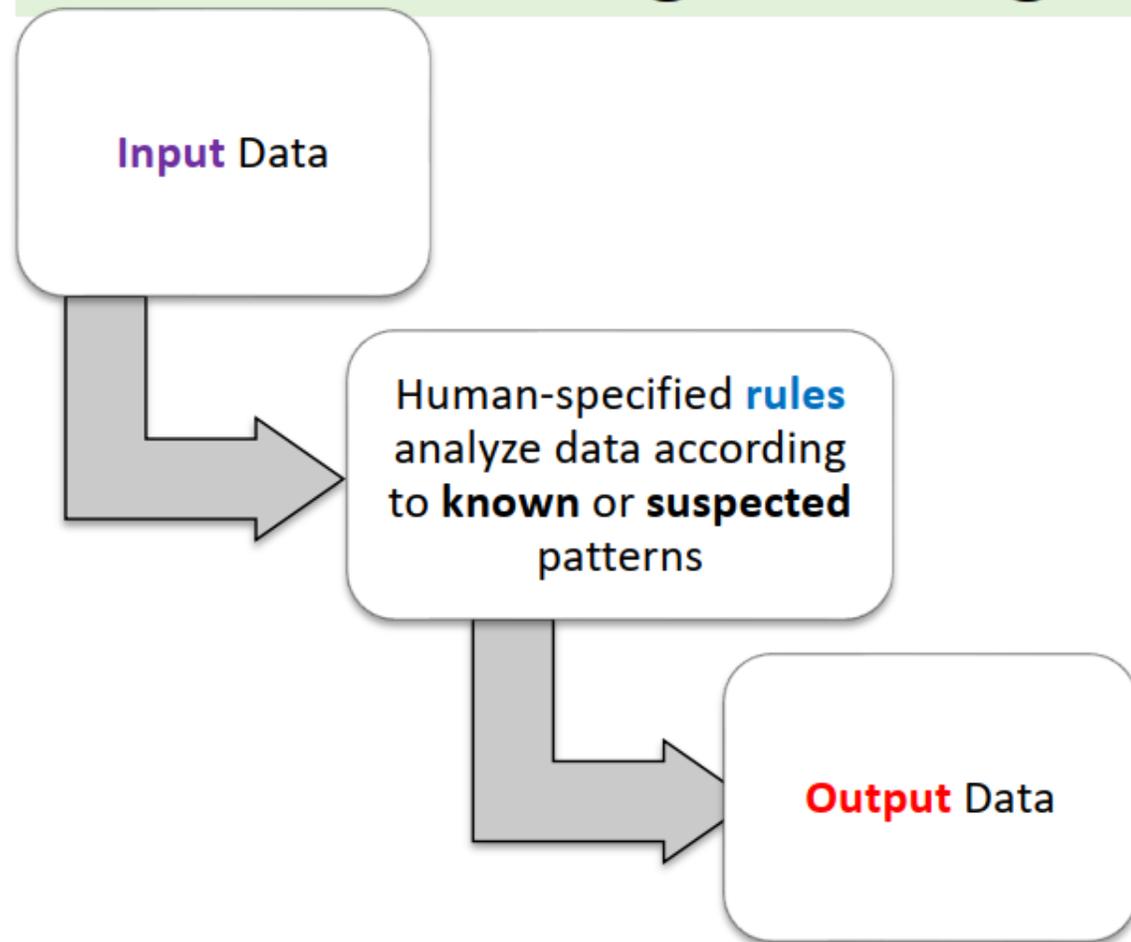


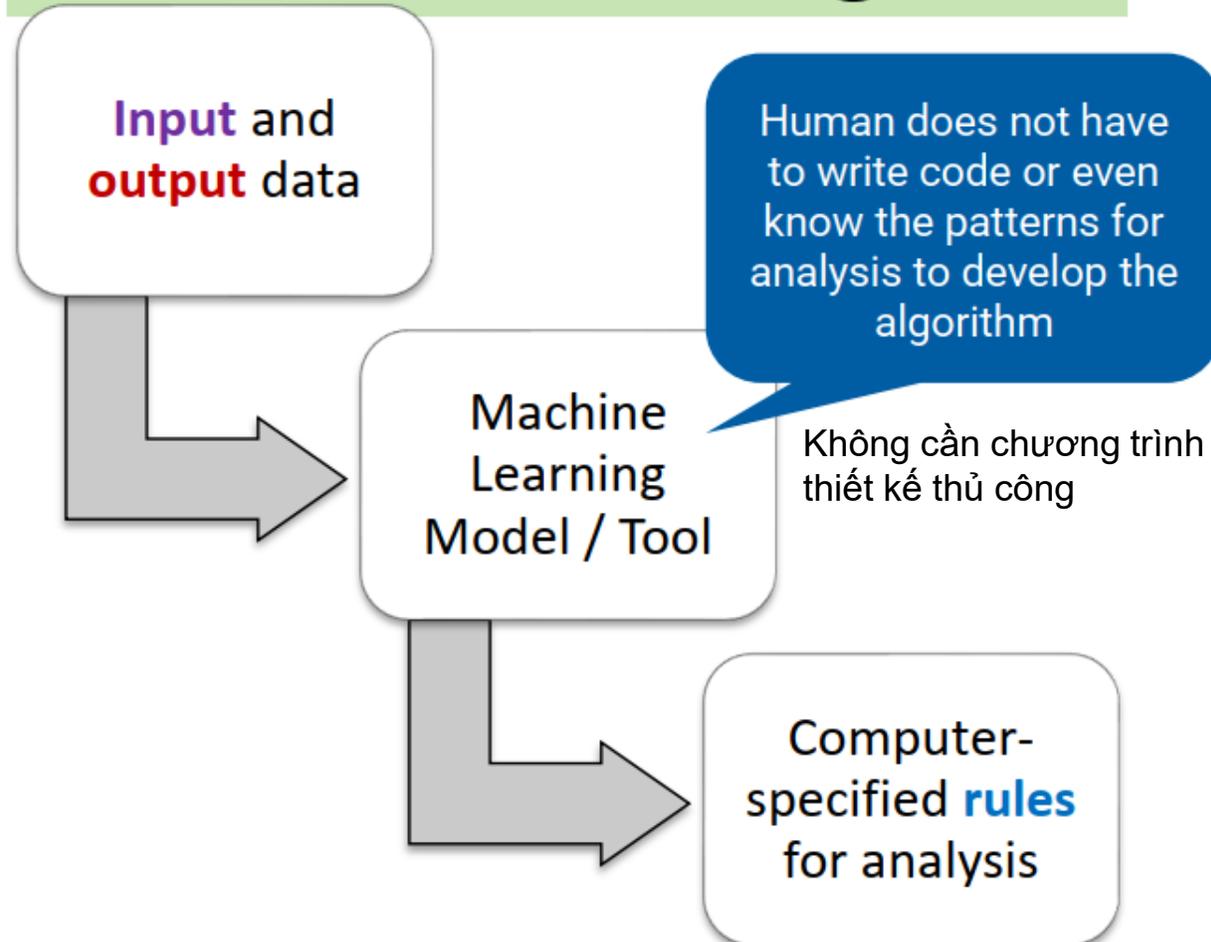
Figure 1.5: Flowcharts showing how the different parts of an AI system relate to each other within different AI disciplines. Shaded boxes indicate components that are able to learn from data.

Machine Learning vs. Traditional Programming

Traditional Programming



Machine Learning



OPEN

Machine learning vs. traditional regression analysis for fluid overload prediction in the ICU

Andrea Sikora¹, Tianyi Zhang², David J. Murphy³, Susan E. Smith¹, Brian Murray⁴, Rishikesan Kamaleswaran^{5,6}, Xianyan Chen², Mitchell S. Buckley⁷, Sandra Rowe⁸ & John W. Devlin^{9,10}✉

(n = 28) were collected at either baseline or 24 h after ICU admission. The optimal traditional logistic regression model was created using backward selection. Supervised, classification-based ML models were trained and optimized, including a meta-modeling approach. Area under the receiver operating characteristic (AUROC), positive predictive value (PPV), and negative predictive value (NPV) were compared between the traditional and ML fluid prediction models. A total of 49 of the 391 (12.5%) patients developed fluid overload. Among the ML models, the XGBoost model had the highest performance (AUROC 0.78, PPV 0.27, NPV 0.94) for fluid overload prediction. The XGBoost model performed similarly to the final traditional logistic regression model (AUROC 0.70; PPV 0.20, NPV 0.94). Feature importance analysis revealed severity of illness scores and medication-related data were the most important predictors of fluid overload. In the context of our study, ML and traditional models appear to perform similarly to predict fluid overload in the ICU. Baseline severity of illness and ICU medication regimen complexity are important predictors of fluid overload.

	AUC	Accuracy	Sensitivity
Traditional regression			
All variables	0.70 (0.53, 0.82)	0.82 (0.76, 0.87)	0.43 (0.19, 0.70)
Stepwise selected regression	0.70 (0.52, 0.82)	0.86 (0.80, 0.90)	0.43 (0.19, 0.70)
Supervised machine learning models			
Random forest	0.76 (0.62, 0.86)	0.83 (0.77, 0.88)	0.56 (0.29, 0.80)
Support vector machine	0.69 (0.51, 0.82)	0.80 (0.74, 0.86)	0.50 (0.24, 0.75)
XGBoost	0.78 (0.62, 0.87)	0.87 (0.81, 0.91)	0.37 (0.15, 0.64)

results^{51,52}. For example, feature importance graphs for the **machine learning analyses** found complexity of the daily ICU medication regimen (i.e., MRC-ICU score), which includes the number of intravenous medication infusions (the primary method to administer medications in this population and a primary source of fluids to a patient), to be an important contributor to fluid overload. In comparison, **in the traditional multivariable regression**, the MRC-ICU score was not associated with fluid overload. This may be because machine learning analyses better account for severity of illness and the response of clinicians to respond to this severity by administering more medication infusions leading to a more complex daily medication regimen; however, the methods applied, including feature importance, preclude causal inference at this juncture. As such, our results highlight the **unique power of machine learning to identify complex relationships** that can be further elucidated via machine-learning based causal inference modeling and other designs aimed at causation^{2,20}.

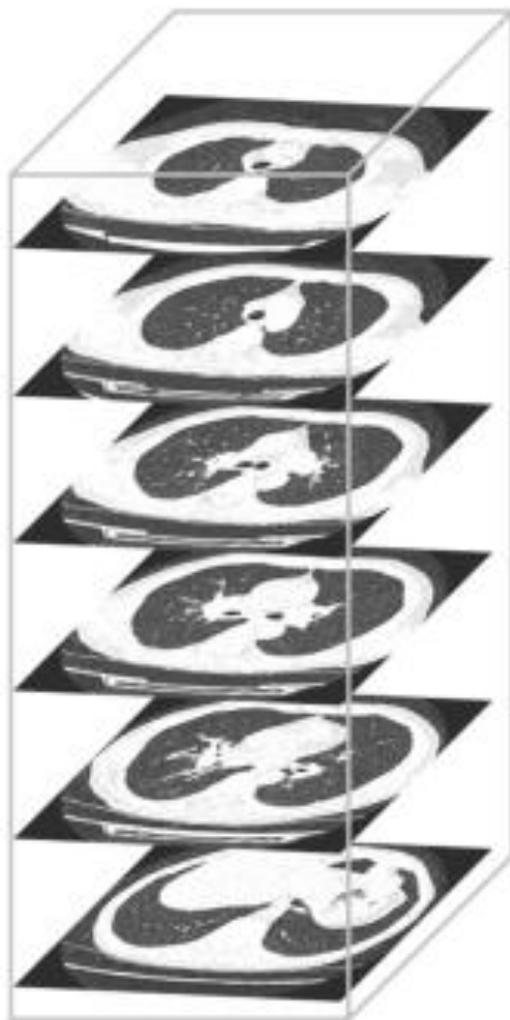
Diagnosis and Severity Assessment of COPD Based on Machine Learning of Chest CT Images

He Sui ^{1,*}, Zanhao Mo ^{1,*}, Ying Wei², Feng Shi ², Kailiang Cheng¹, Lin Liu¹

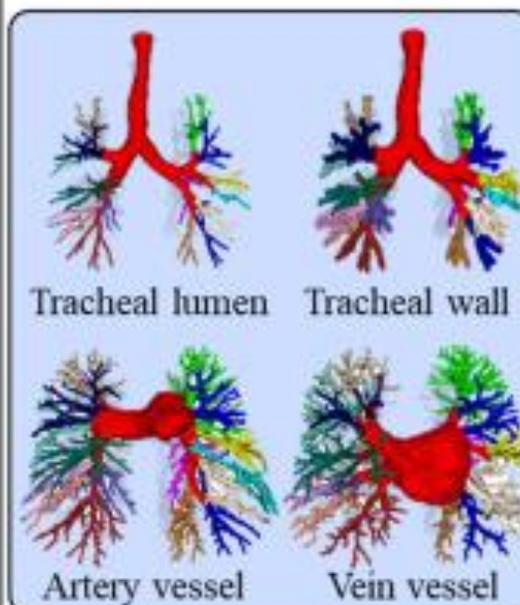
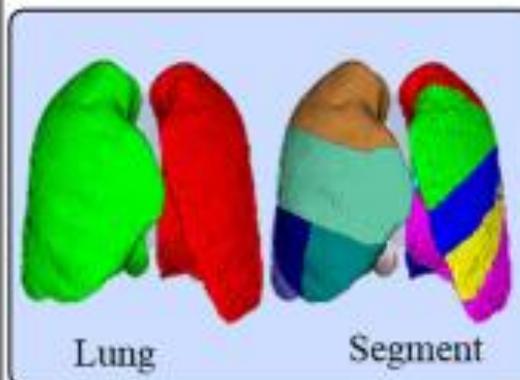
Patients and Methods: The study retrospectively included 173 COPD patients and 176 healthy controls from December 2017 to June 2023. Deep learning segmentation modules were used to automatically segment the obtained chest CT images for lung parenchyma, airway, pulmonary artery, and vein. Imaging features were extracted from these segmented regions. The most reliable and relevant features were selected using Mann–Whitney *U*-test with a significant p-value of 0.05 and the least absolute shrinkage and selection operator (LASSO) method. Machine learning models were established through support vector machine (SVM) classifier in the training set and further tested in the internal testing set. Additional tests were performed on an external testing set with 68 individuals.

Results: In the machine learning model for COPD diagnosis, the image model achieved AUC values of 0.981 and 0.977 in the training and testing sets, with corresponding accuracies of 0.949 and 0.956 respectively. For COPD severity grading, the image model

CT image

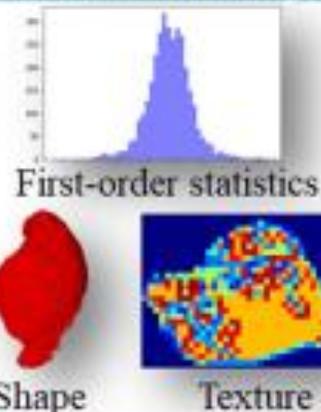


Segmentation

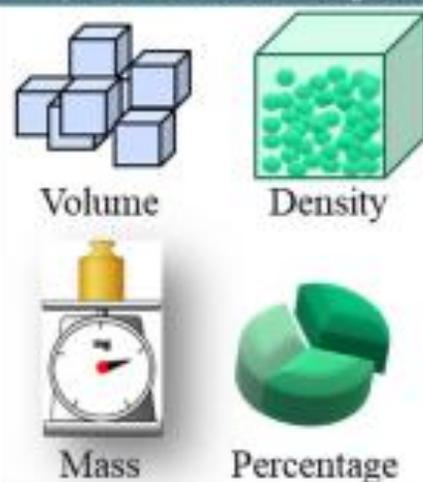


Feature extraction

Radiomics features (2100 features/subject)

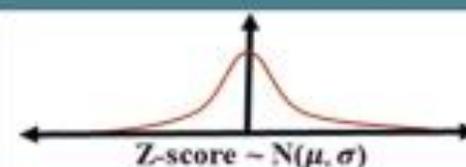


CT quantitative features (320 features/subjects)

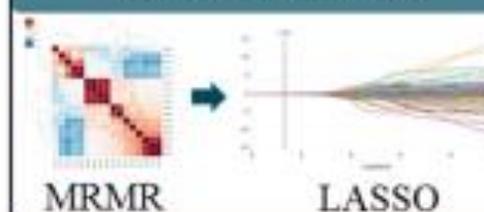


Feature analysis

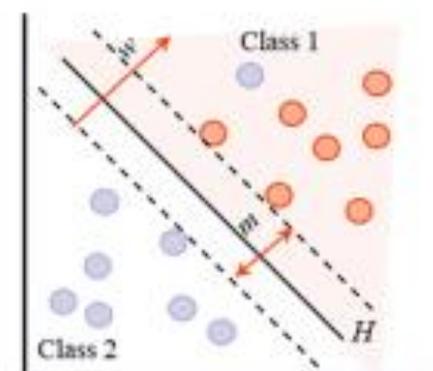
Z-score normalization



Feature selection

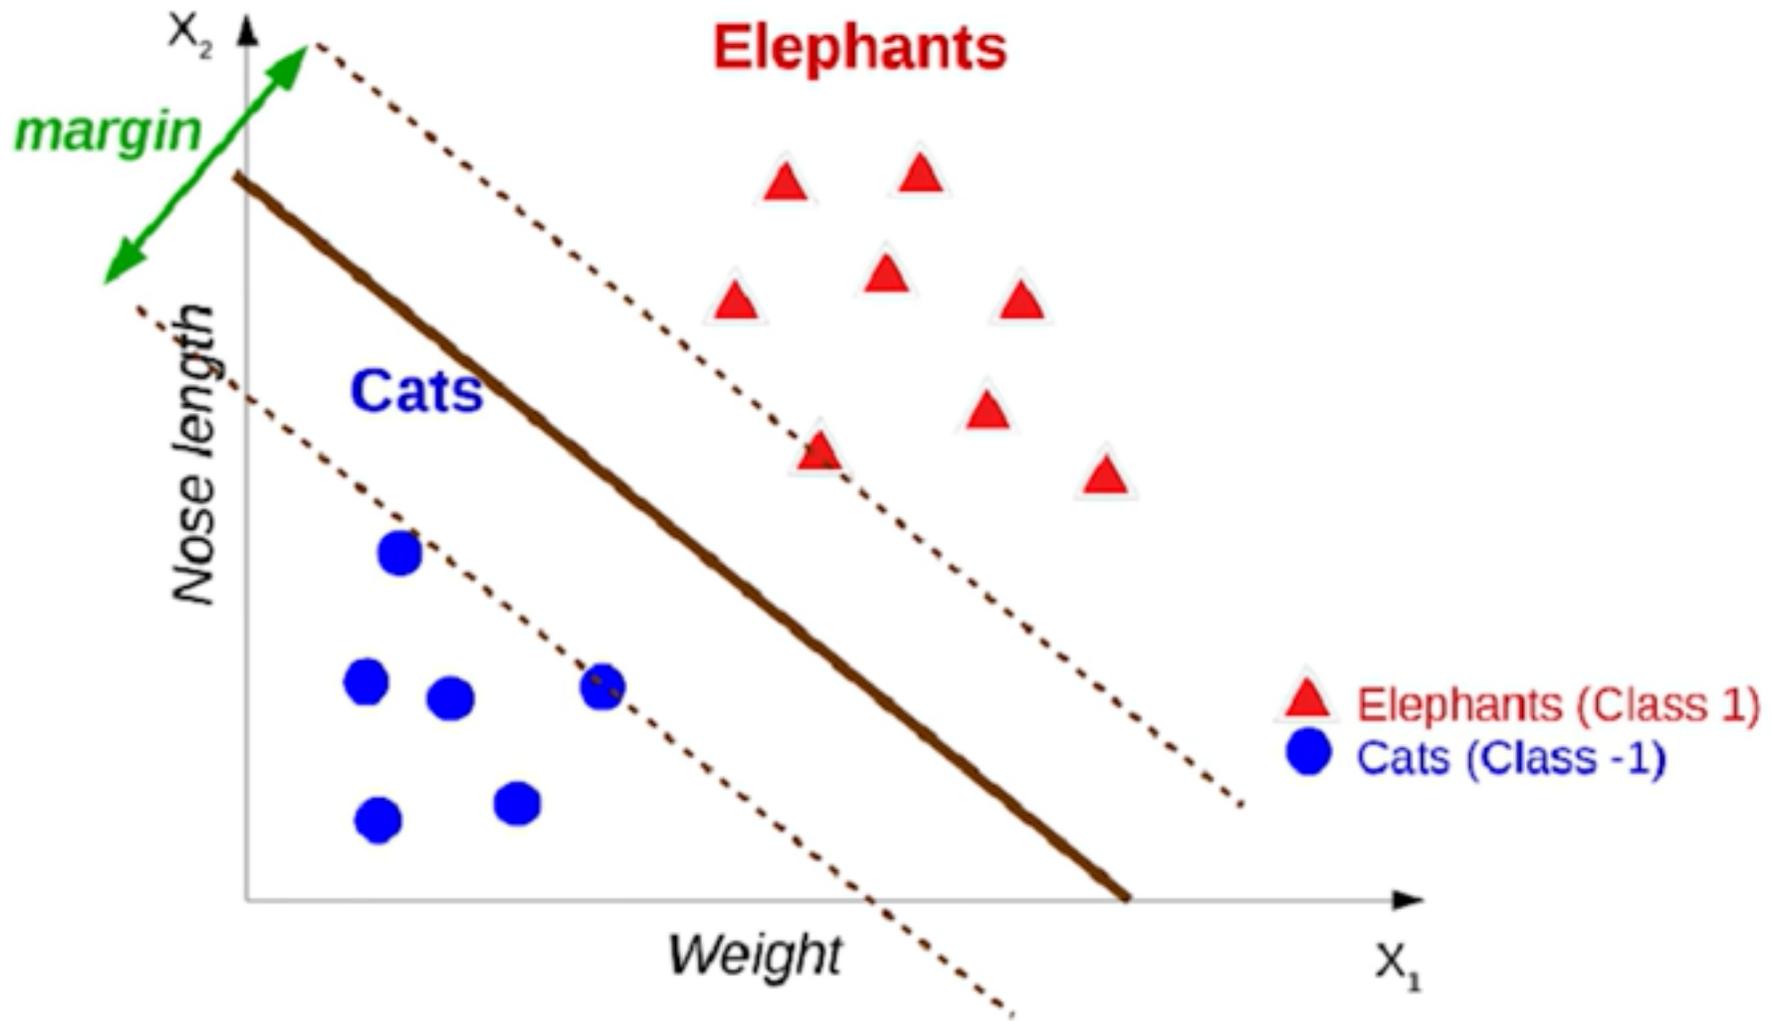


Model construction



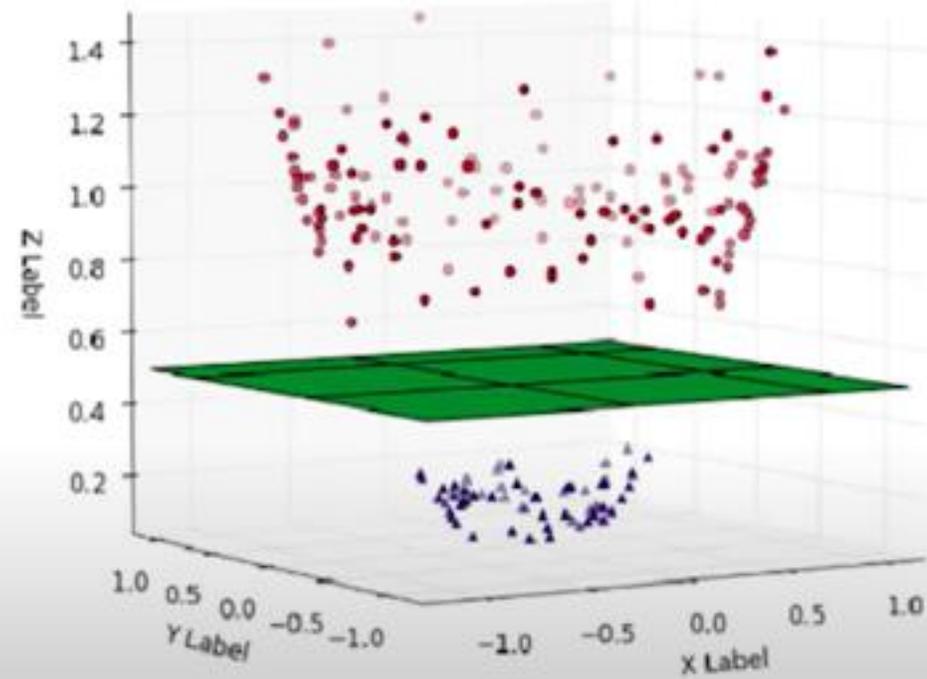
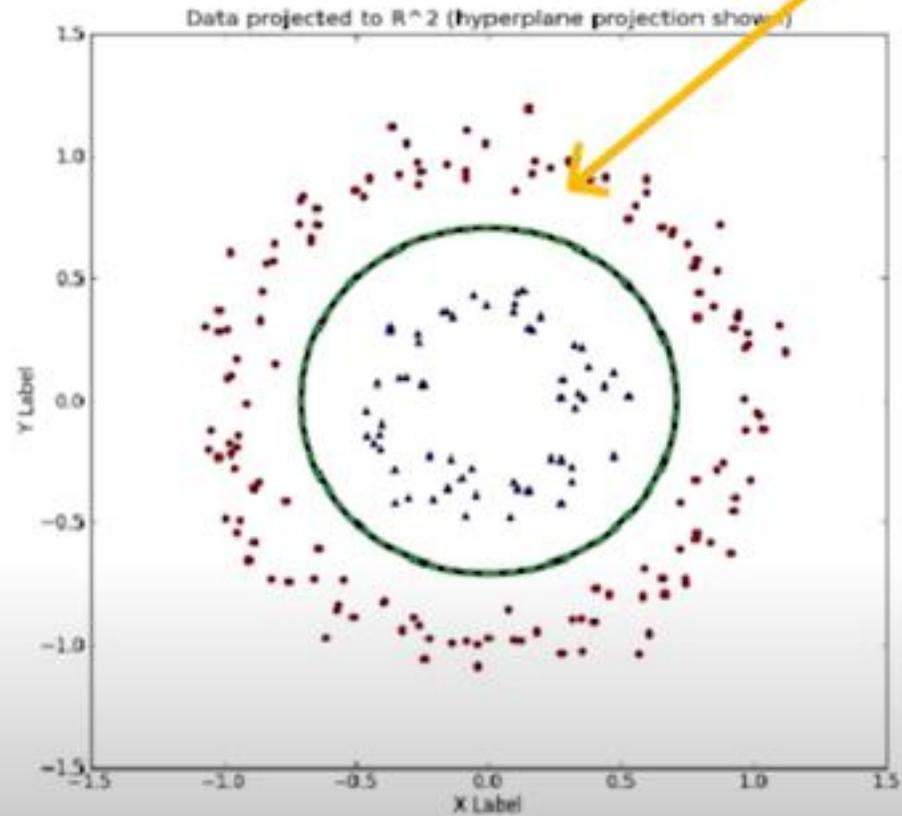
COPD
diagnosis

COPD
grading

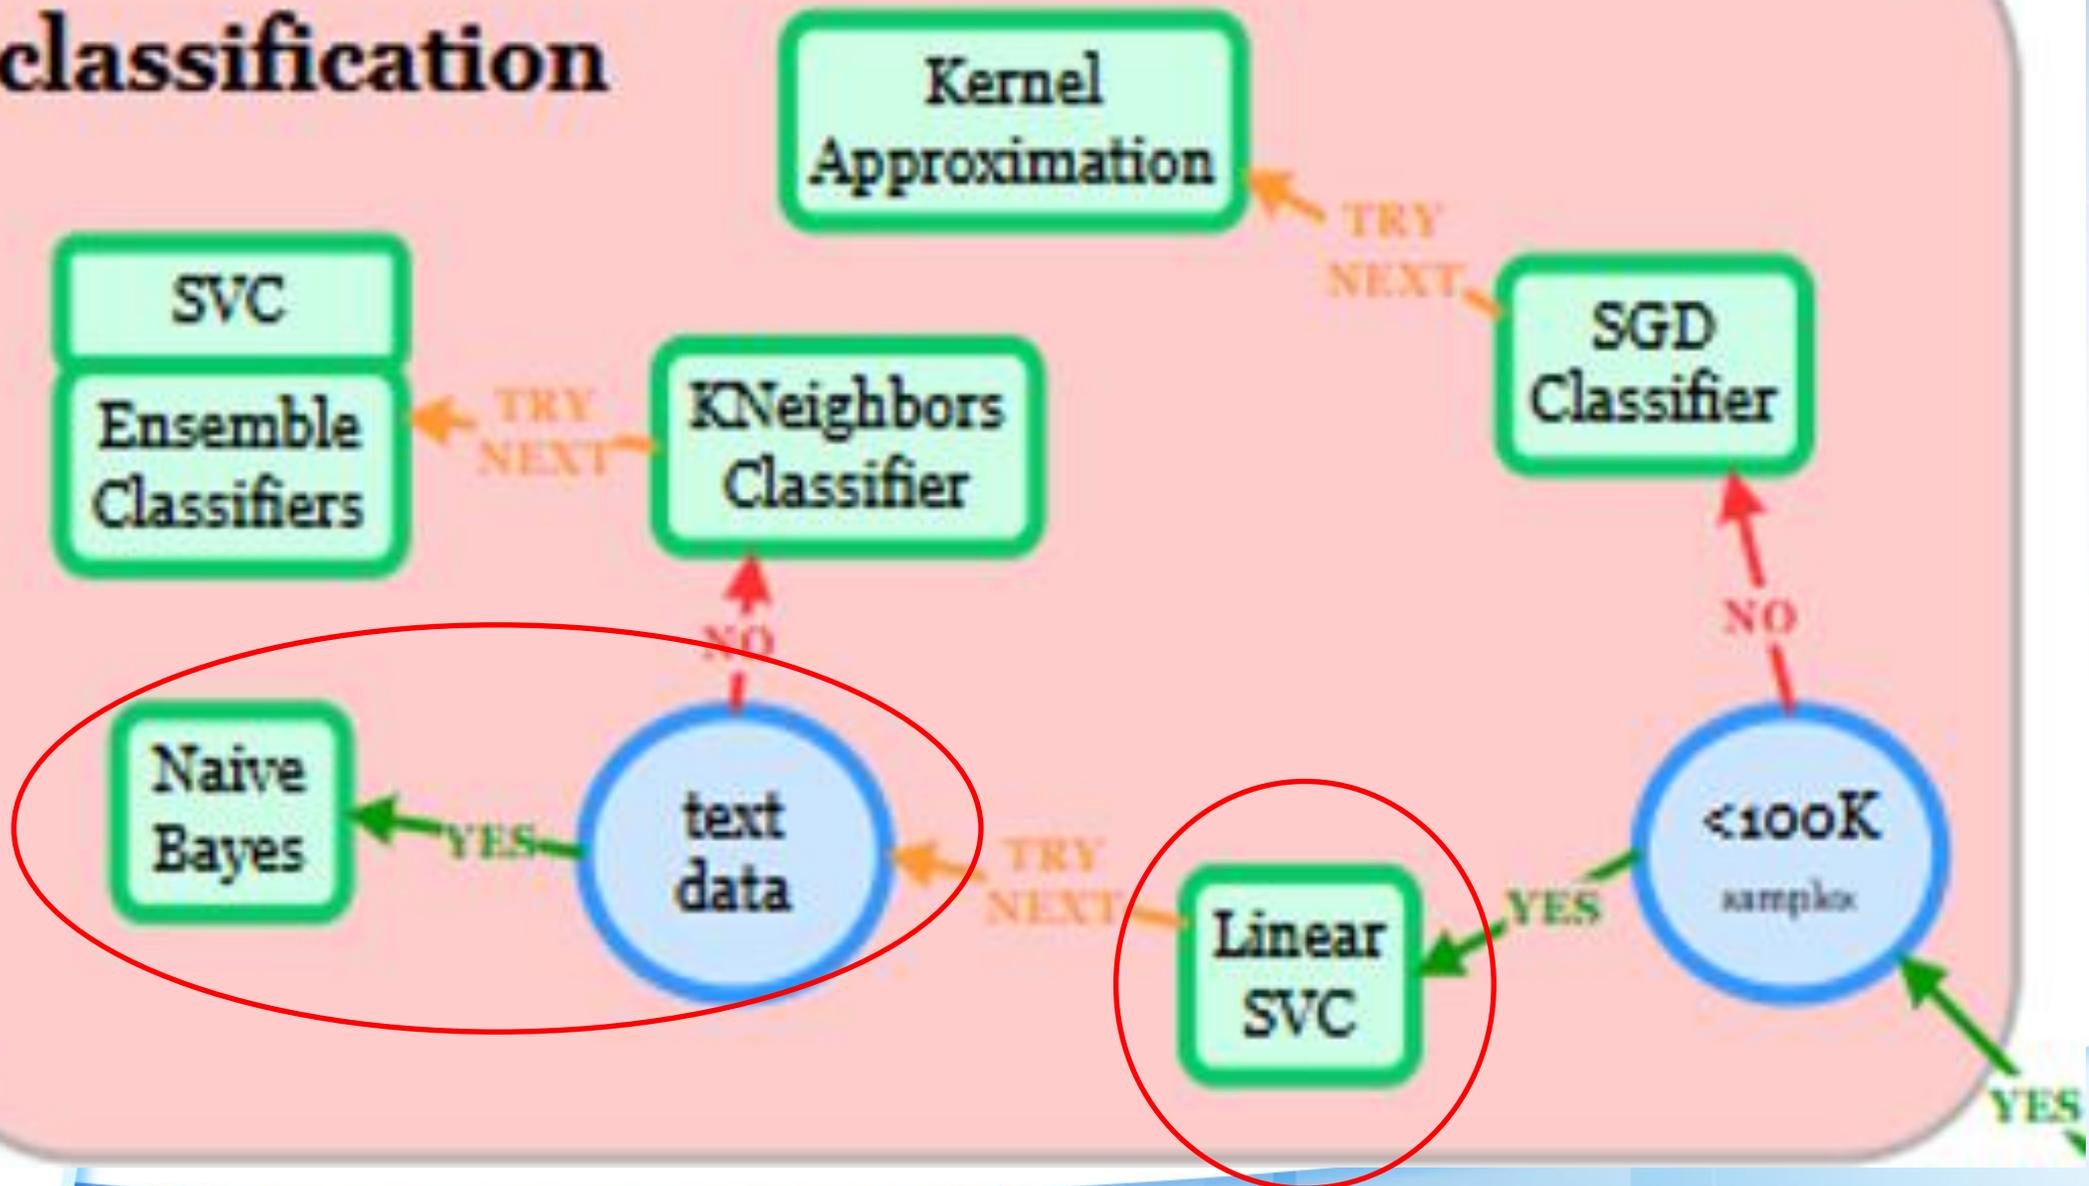


Kernel function

NON LINEAR DECISION BOUNDARIES



classification



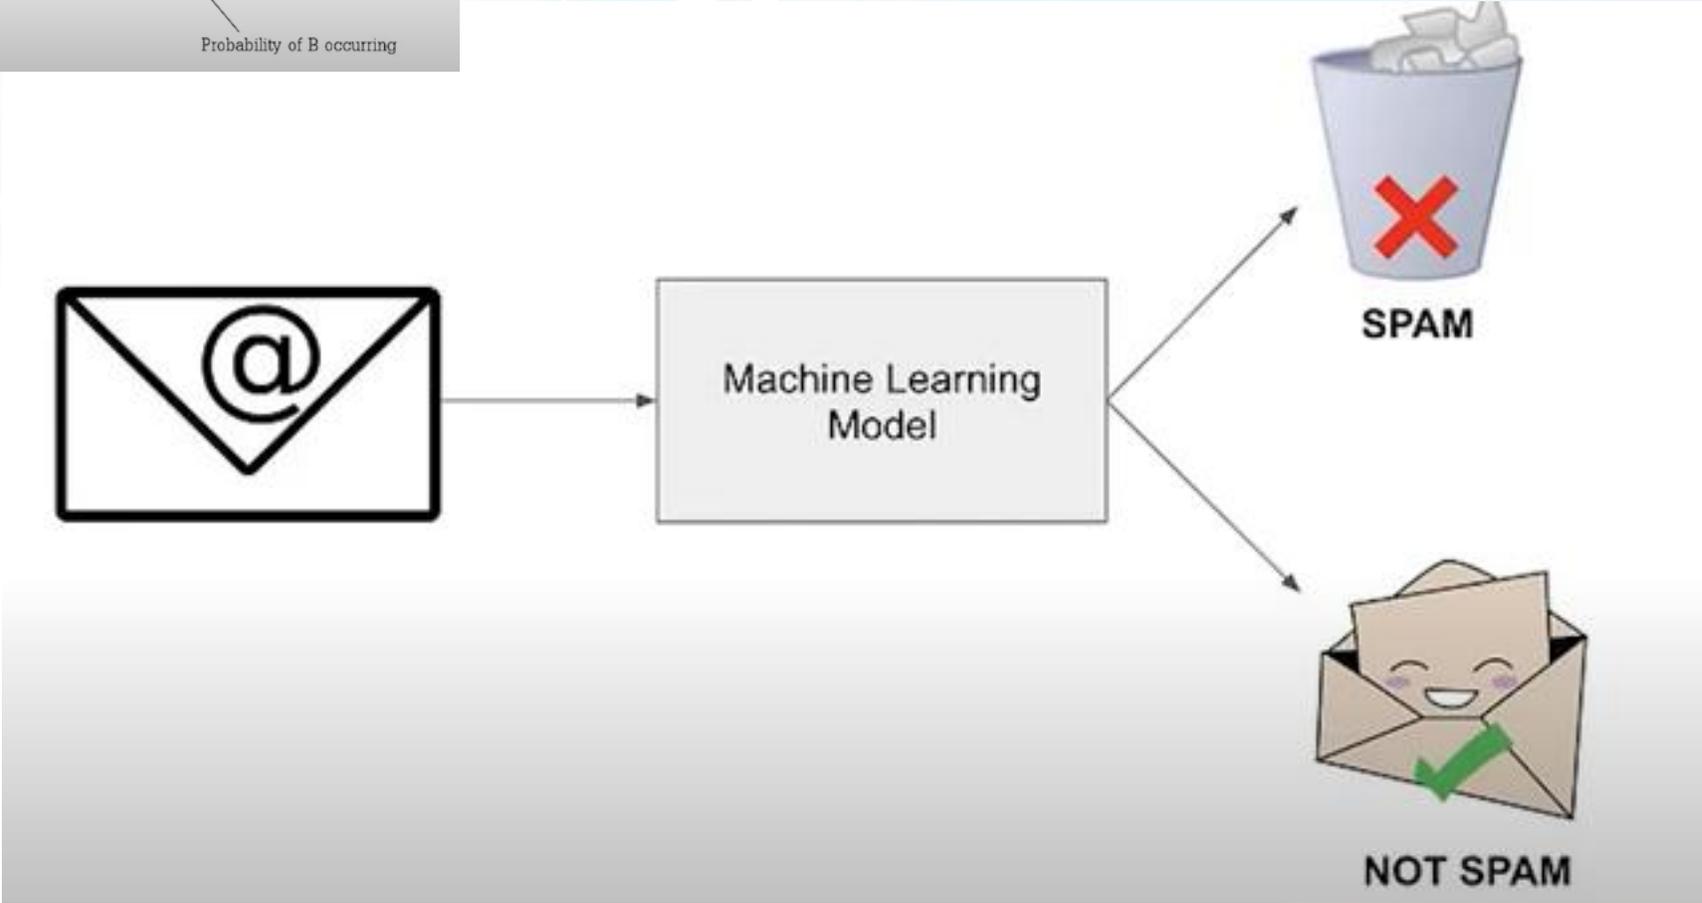
Probability of B occurring given evidence A has already occurred

Probability of A occurring

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

Probability of A occurring given evidence B has already occurred

Probability of B occurring



	Label	SMS
0	spam	SECRET PRIZE! CLAIM SECRET PRIZE NOW!!
1	ham	Coming to my secret party?
2	spam	Winner! Claim secret prize now!



	Label	secret	prize	claim	now	coming	to	my	party	winner
0	spam	2	2	1	1	0	0	0	0	0
1	ham	1	0	0	0	1	1	1	1	0
2	spam	1	1	1	1	0	0	0	0	1

$$P(\textit{spam}|\textit{penis}, \textit{viagra})$$

$$= \frac{P(\textit{penis}|\textit{spam}) * P(\textit{viagra}|\textit{spam}) * P(\textit{spam})}{P(\textit{penis}) * P(\textit{viagra})}$$

$$= \frac{\frac{24}{30} * \frac{20}{30} * \frac{30}{74}}{\frac{25}{74} * \frac{51}{74}} = 0.928$$

92.8% SPAM

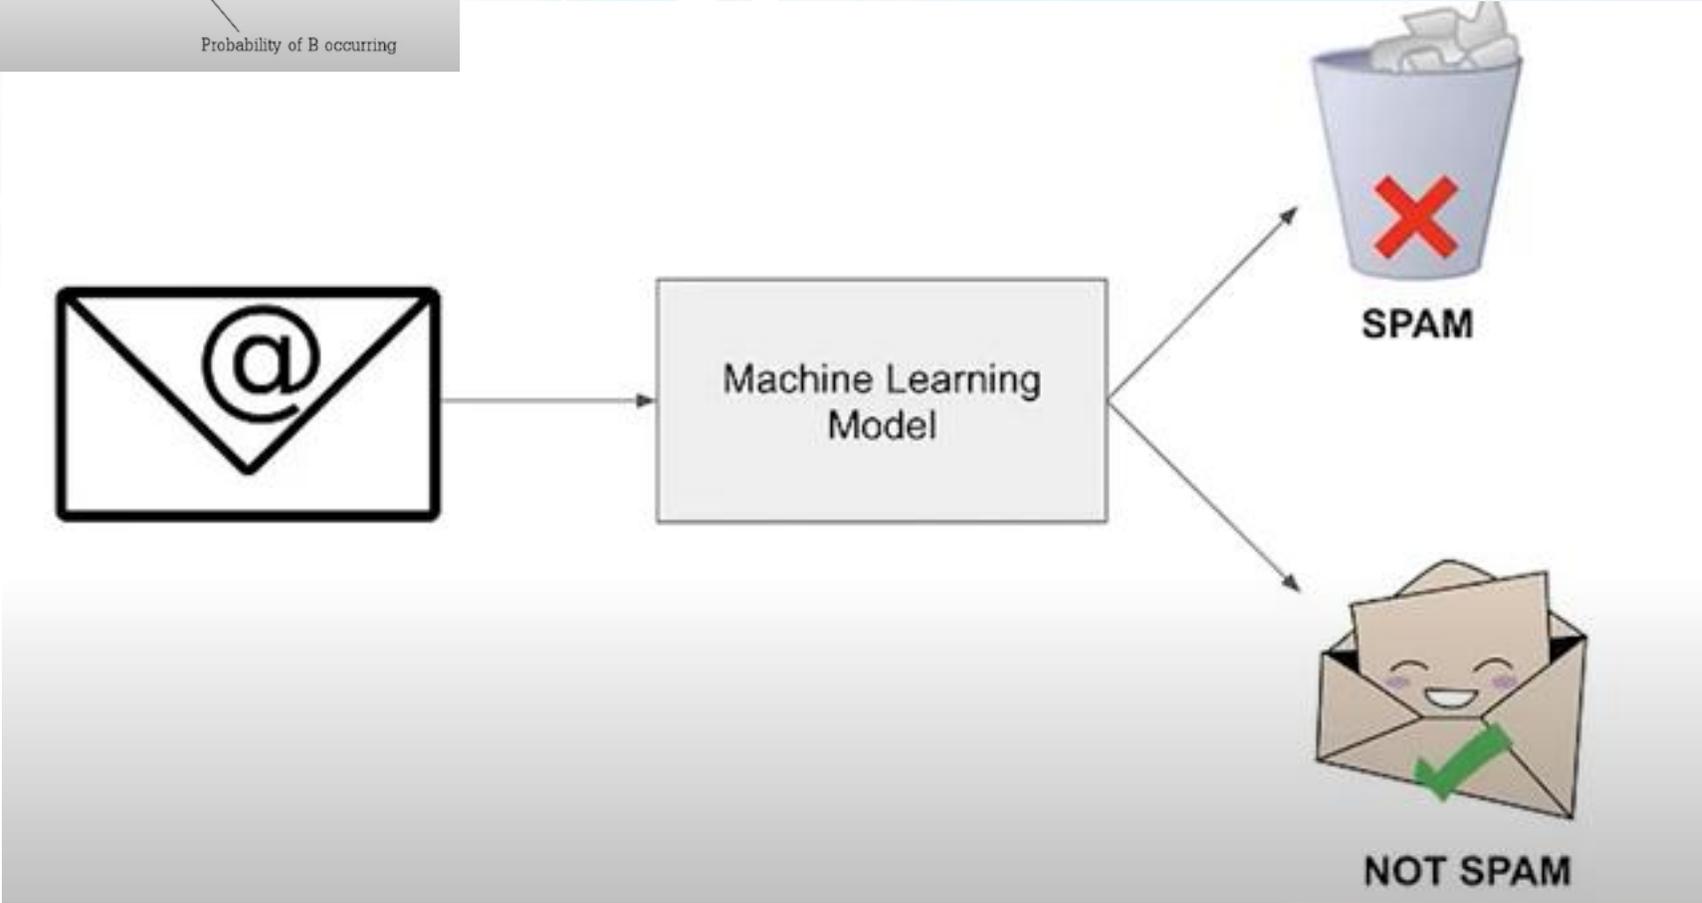
Probability of B occurring given evidence A has already occurred

Probability of A occurring

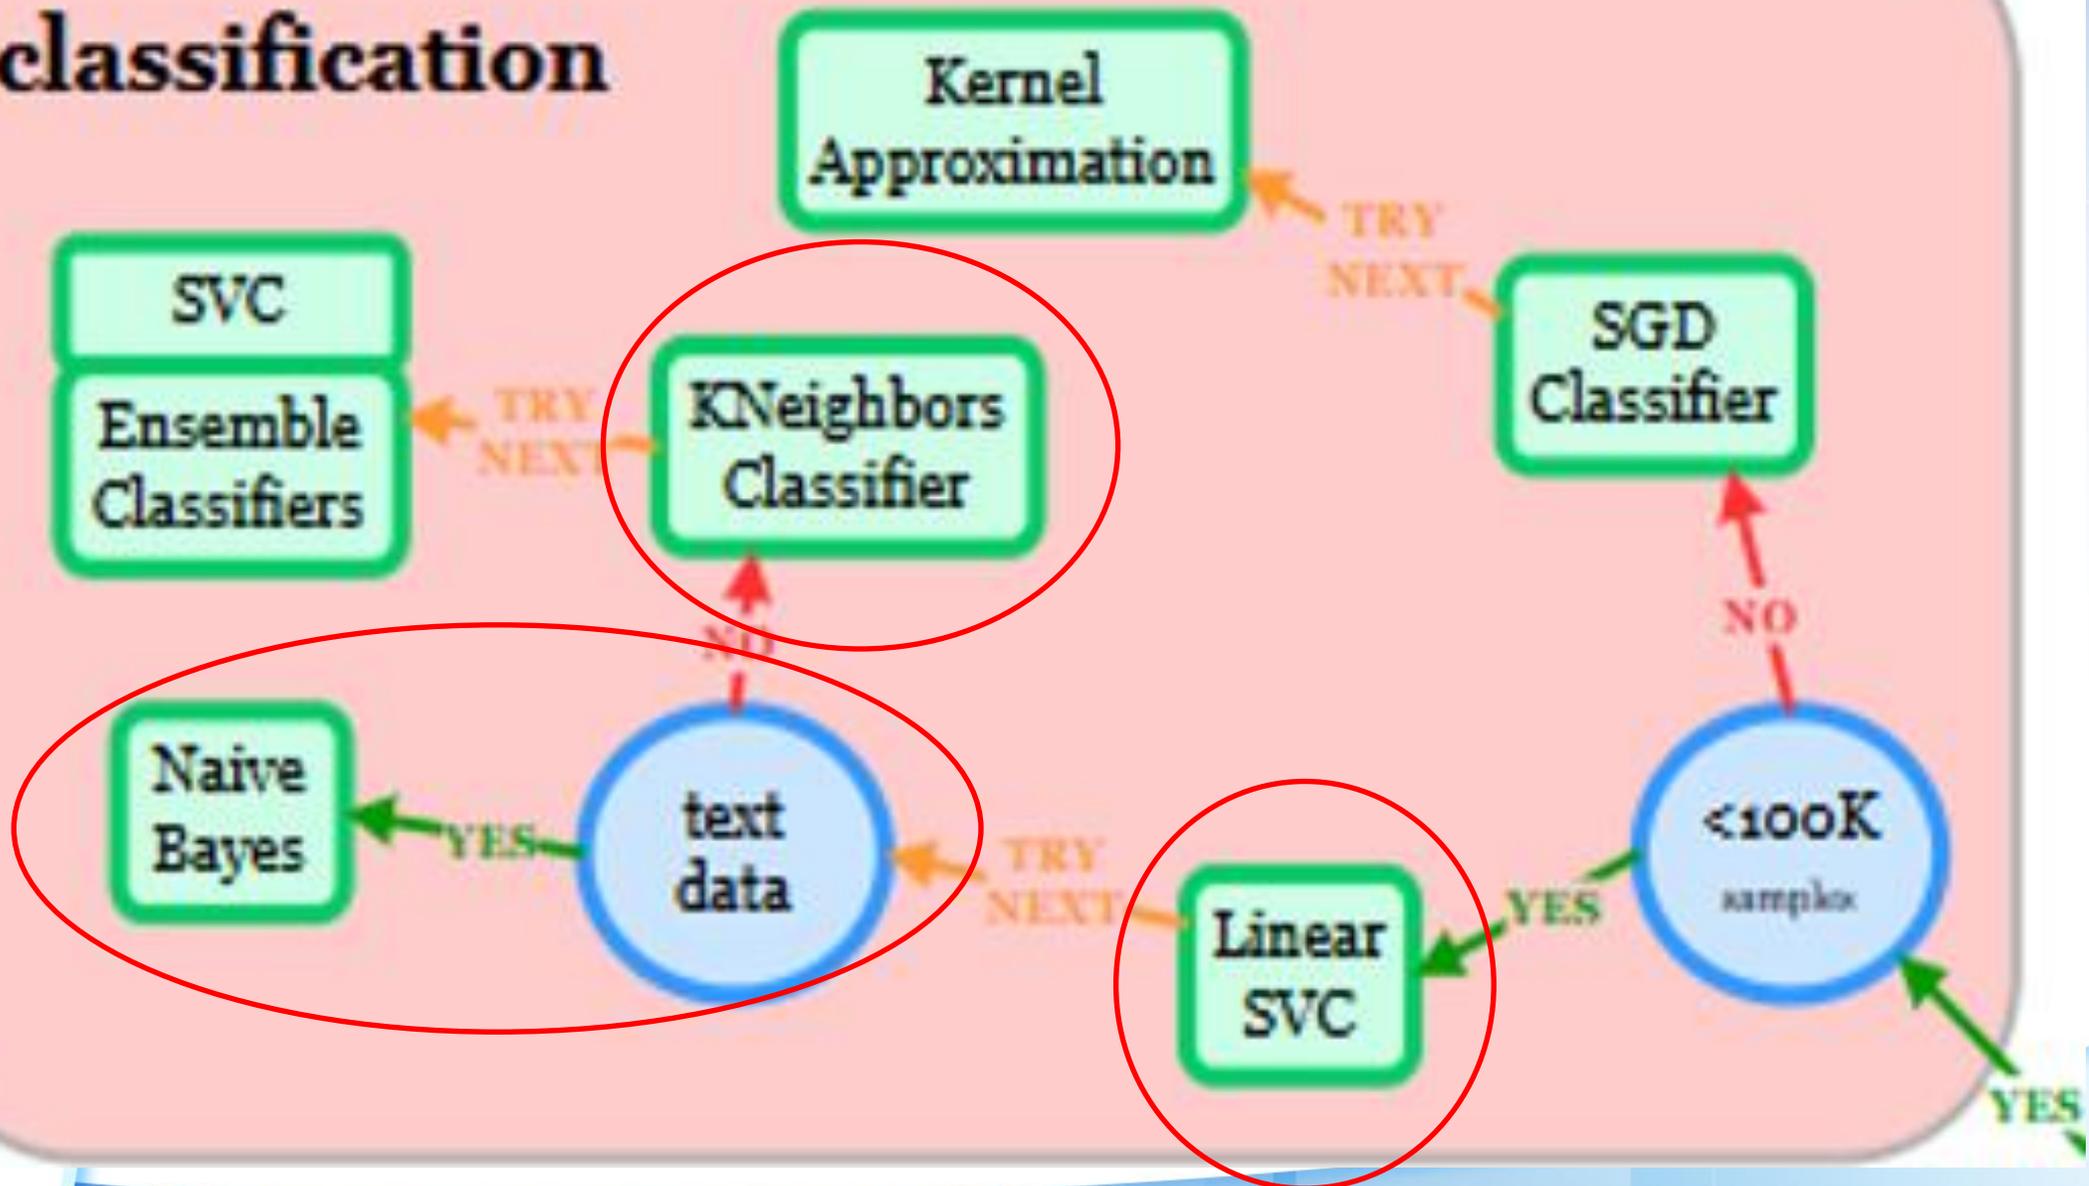
$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

Probability of A occurring given evidence B has already occurred

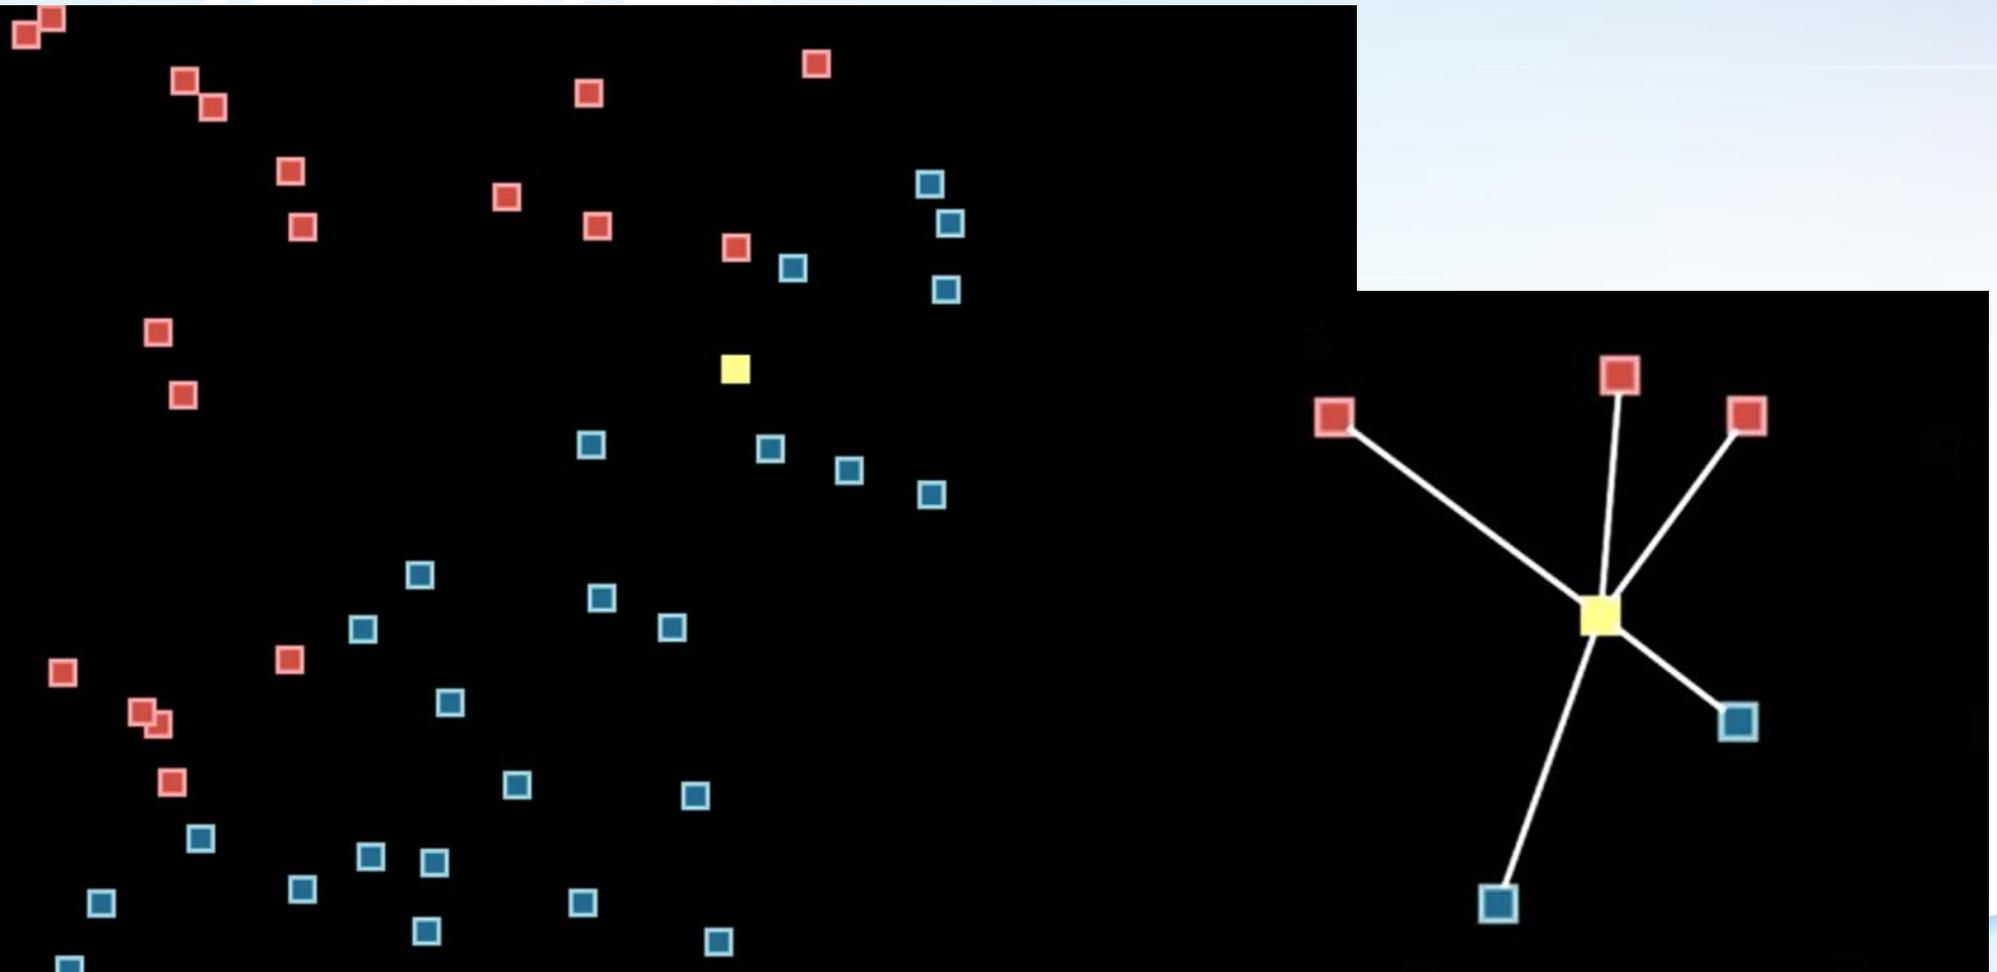
Probability of B occurring

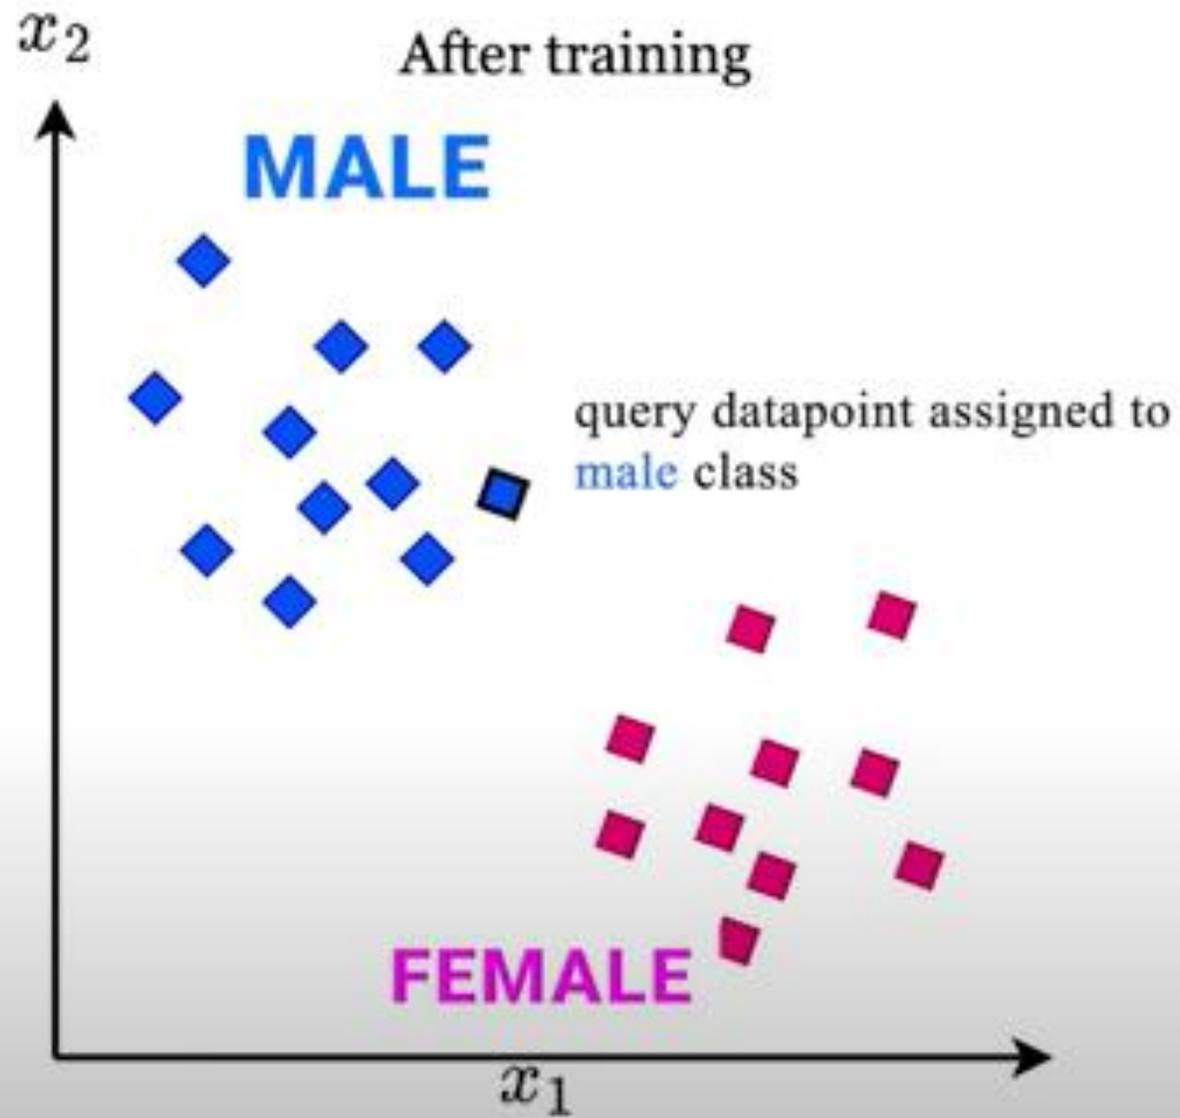
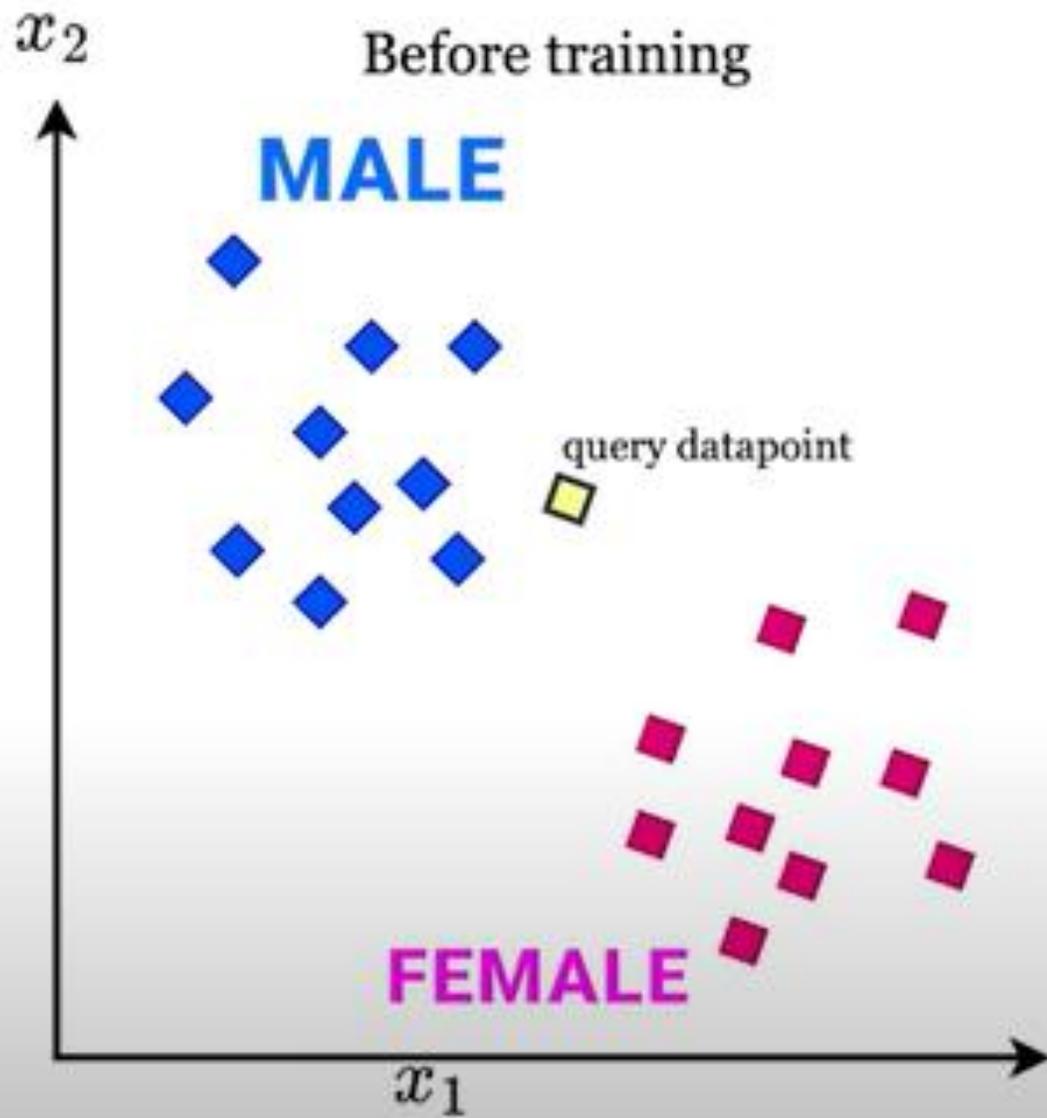


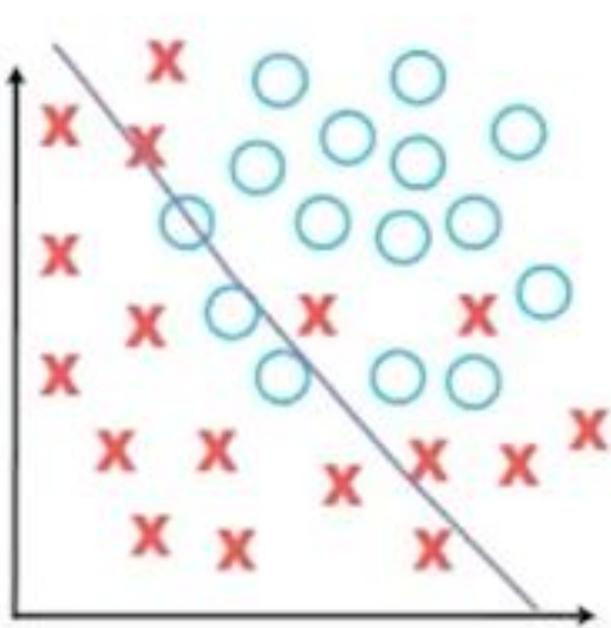
classification



K-nearest neighborhood



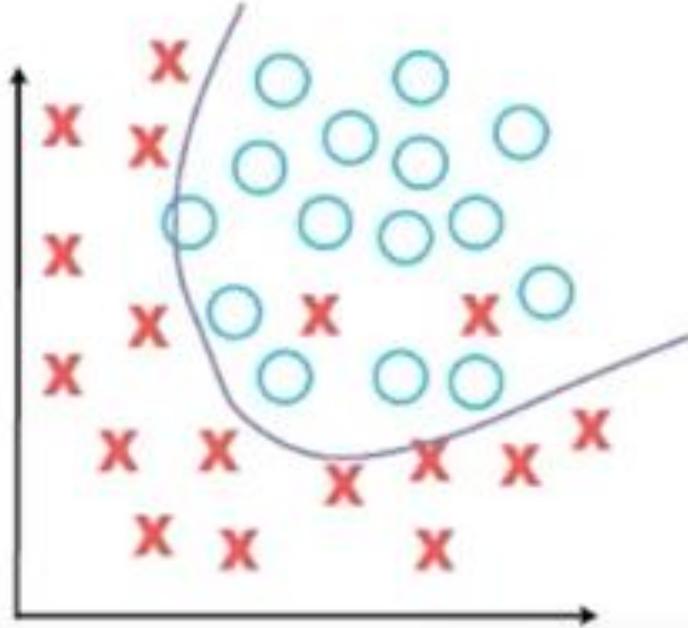




Under-Fitting

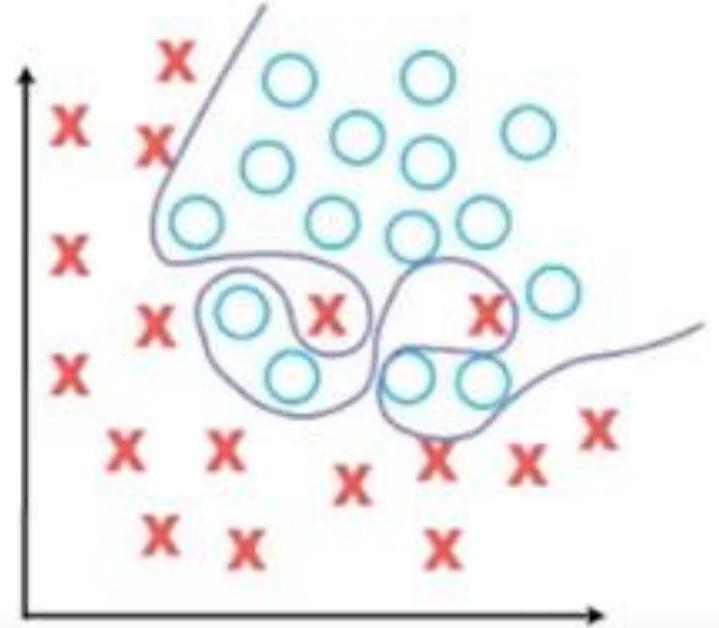
(too simple to explain the variance)

K=1000



Appropriate-Fitting

K=5

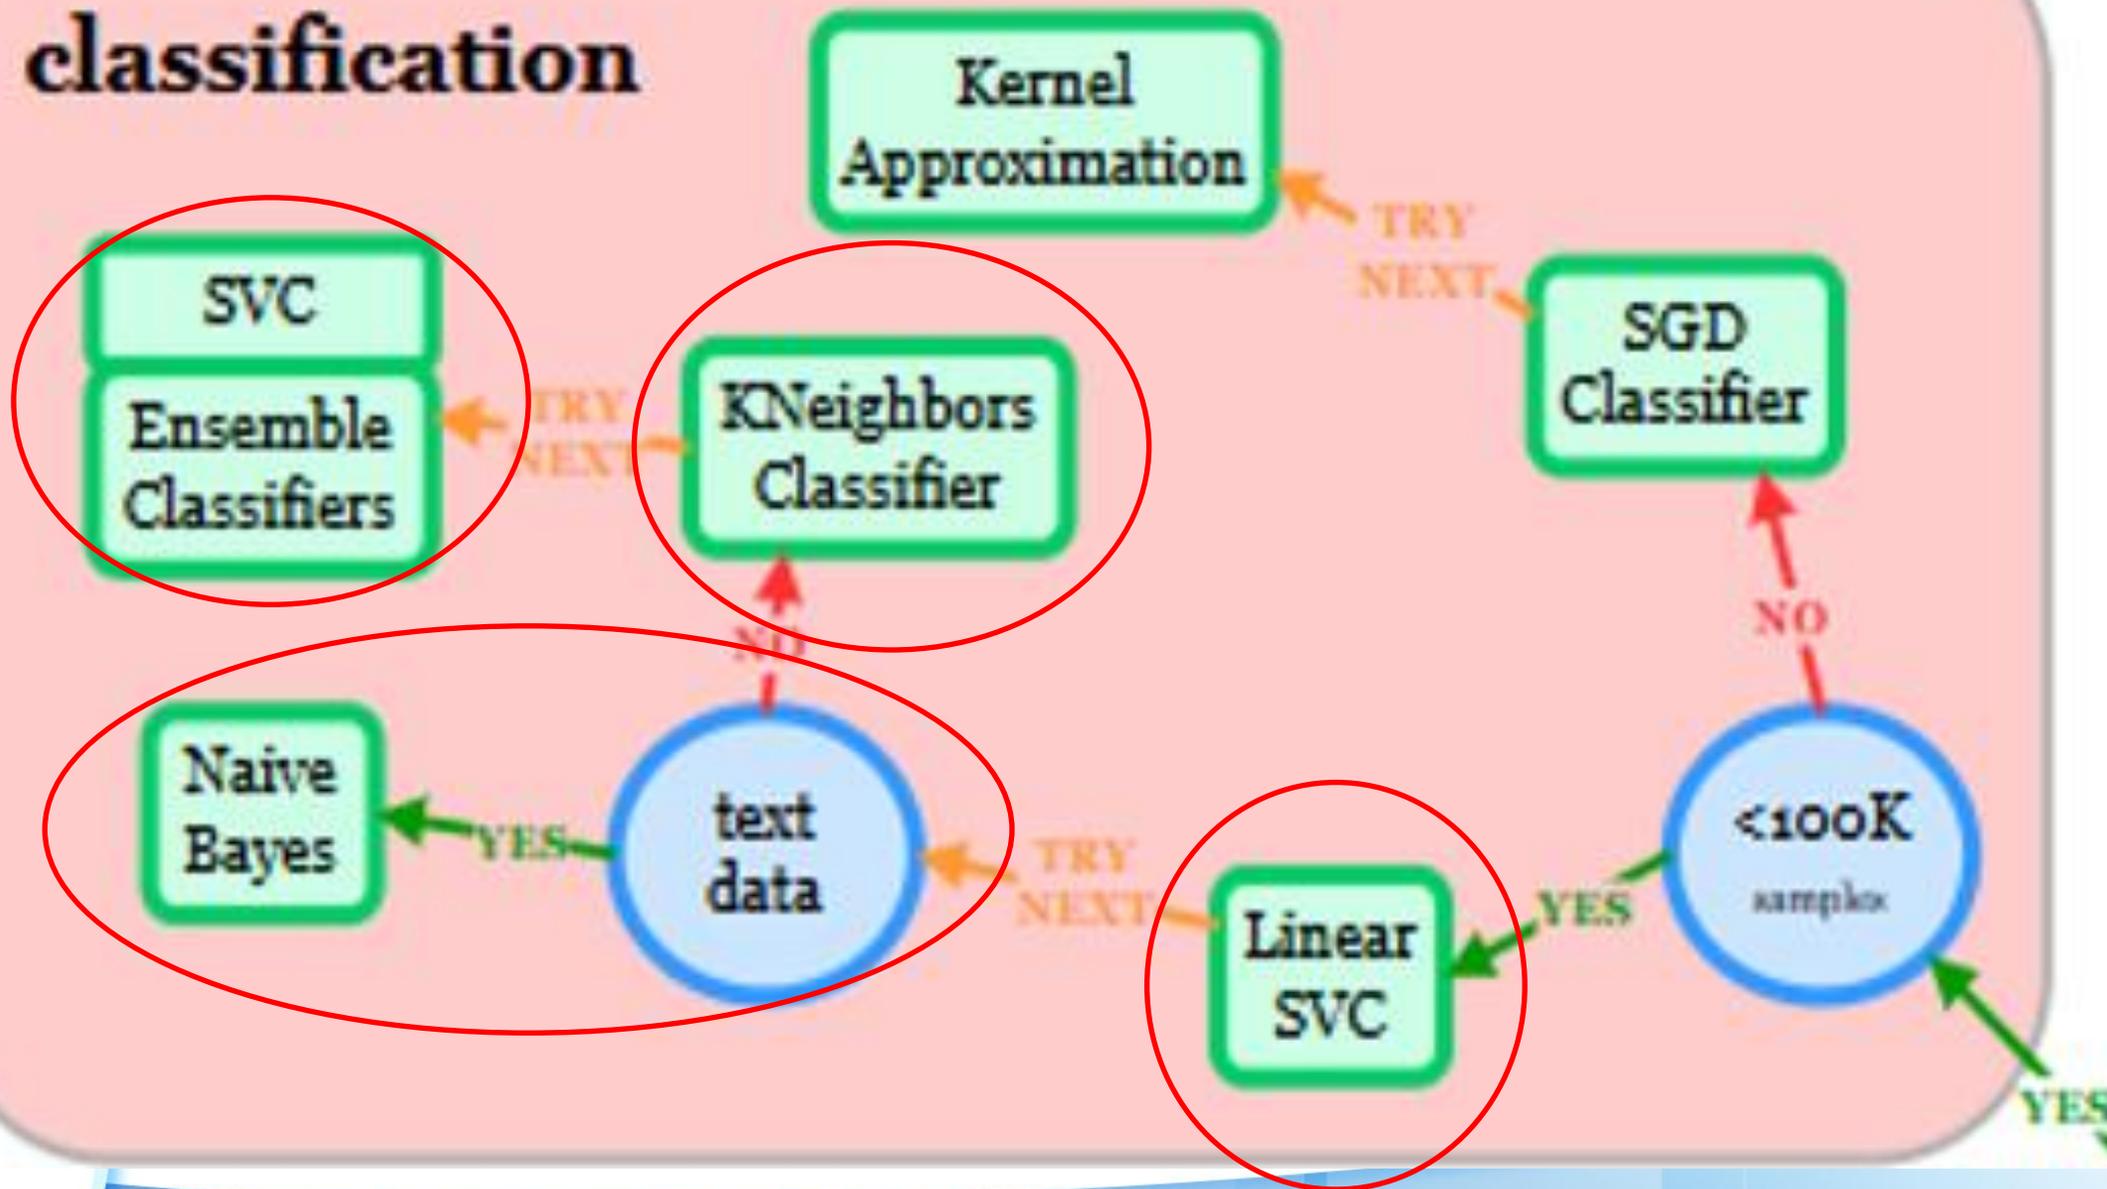


Over-Fitting

(force-fitting – too good to be true)

K=1

classification



Cây quyết định (Decision Tree - CART)

- **CART là gì?** Viết tắt của *Classification and Regression Trees*. Đây là thuật toán phân nhánh dữ liệu dựa trên các câu hỏi Yes/No.
- **Cấu trúc:**
 - **Root Node (Nút gốc):** Biến số quan trọng nhất (ví dụ: Chỉ số mảng bám).
 - **Decision Nodes (Nút quyết định):** Các tiêu chí phân loại tiếp theo (ví dụ: Độ sâu túi nha chu).
 - **Leaf Nodes (Lá):** Kết luận cuối cùng (ví dụ: Viêm lợi hay Viêm nha chu).
- Cực kỳ trực quan, giống như cách các bác sĩ hội chẩn để đưa ra chẩn đoán.

OPEN **Development of a decision tree model for predicting the malignancy of localized gingival enlargements based on clinical characteristics**

Pawat Sripodok¹, Puangwan Laphthanasupkul¹, Tawepong Arayapisit²,

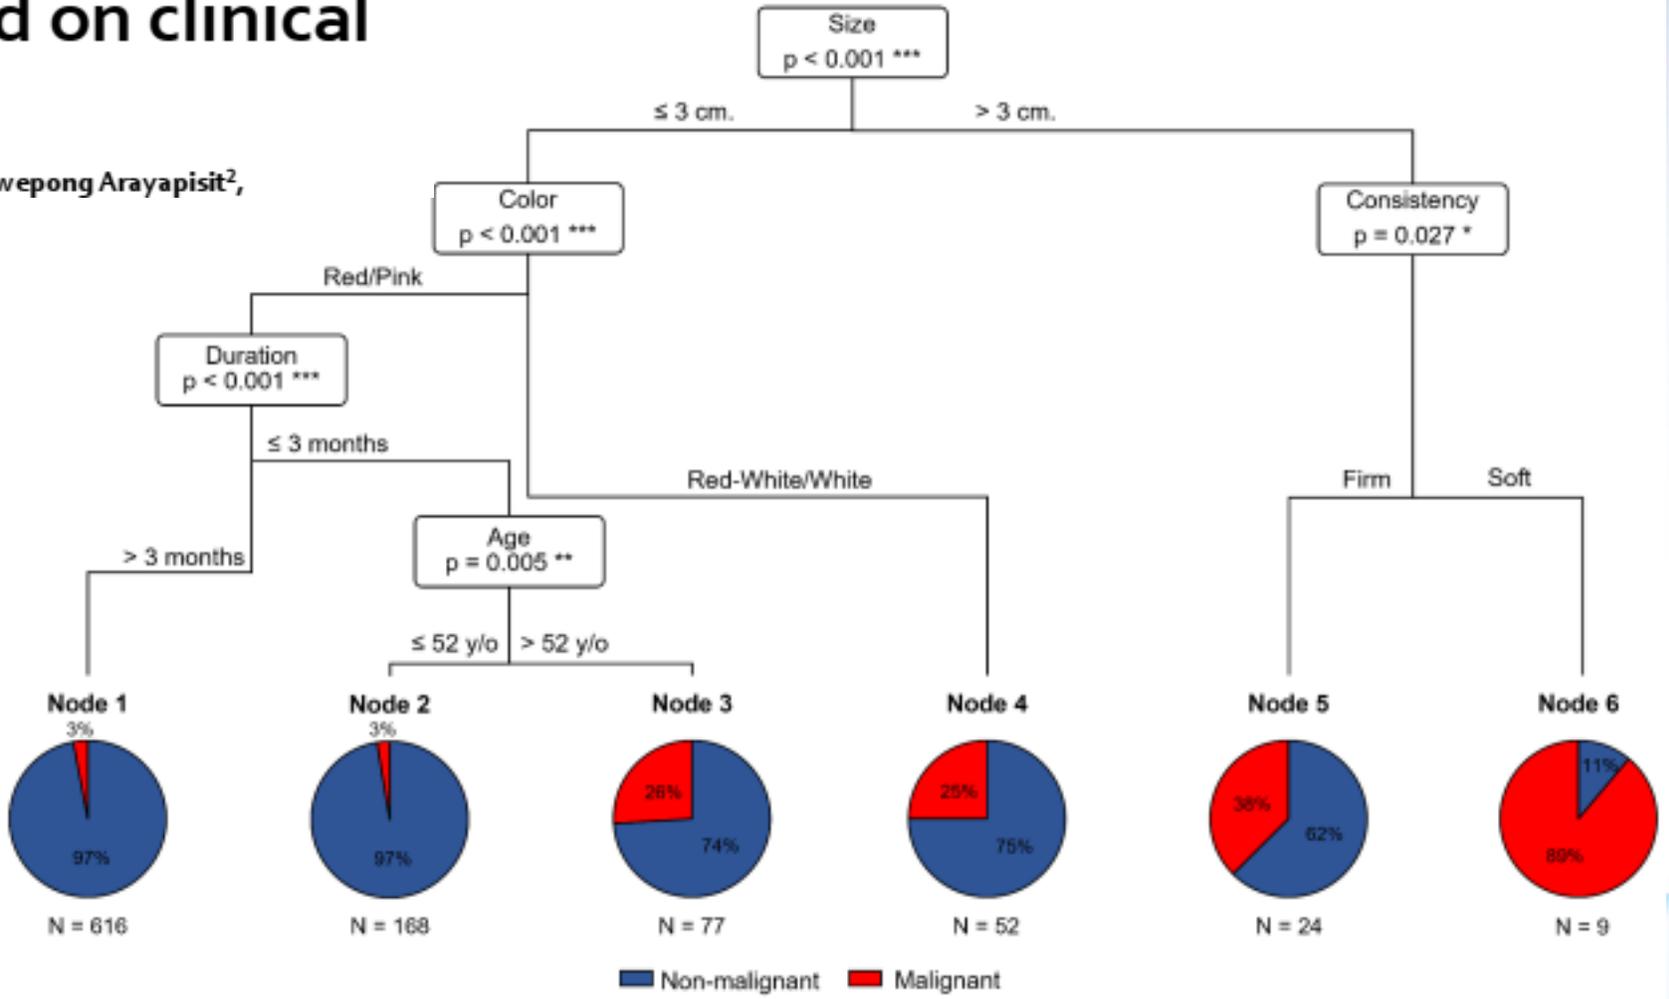


Fig. 1. Decision tree model for predicting malignant LGEs.

Utilizing decision tree machine learning model to map dental students' preferred learning styles with suitable instructional strategies

$$G = 1 - \sum_{i=1}^C p_i^2$$

```
> 1 - (92^2 + 17^2 + 82^2) / 191^2
```

```
[1] 0.5757518
```

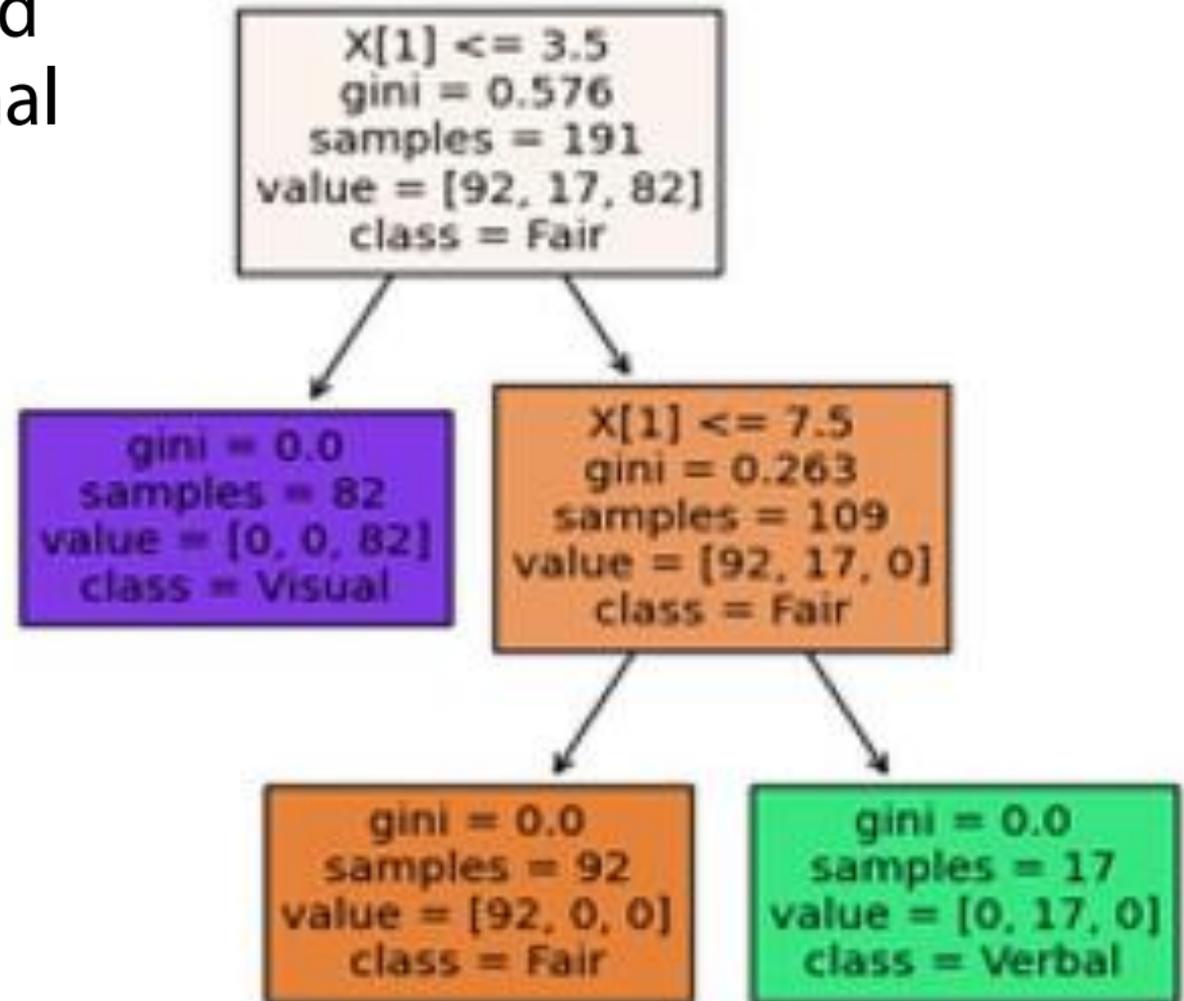
```
> 1 - (92^2 + 17^2) / 109^2
```

```
[1] 0.2632775
```

```
> 1 - (92^2) / 92^2
```

```
[1] 0
```

Learning Style: Input



Từ Một cây đến Một "Khu rừng" (Ensemble Learning)

- **Vấn đề:** Một cây quyết định đơn lẻ dễ bị "học vẹt" (overfitting) hoặc sai lệch nếu dữ liệu nhiều.
- **Giải pháp:** Kết hợp nhiều mô hình lại với nhau để đưa ra kết quả chính xác và ổn định hơn.
- **Ba chiến lược chính:**
 - Bagging (Bootstrap Aggregating)
 - Boosting
 - Stacking

Kỹ thuật Bagging & Random Forest

- Bagging: Giảm thiểu sai số bằng cách lấy trung bình
- **Cơ chế:** Xây dựng nhiều cây quyết định độc lập trên các tập dữ liệu con khác nhau, sau đó lấy số phiếu bầu đa số (Random forest)
- **Ứng dụng nha khoa:**
 - Dự đoán khả năng thành công của một ca cấy ghép Implant dựa trên mật độ xương, tiền sử bệnh lý và hệ cấy ghép

Predicting the Failure of Dental Implants Using Supervised Learning Techniques

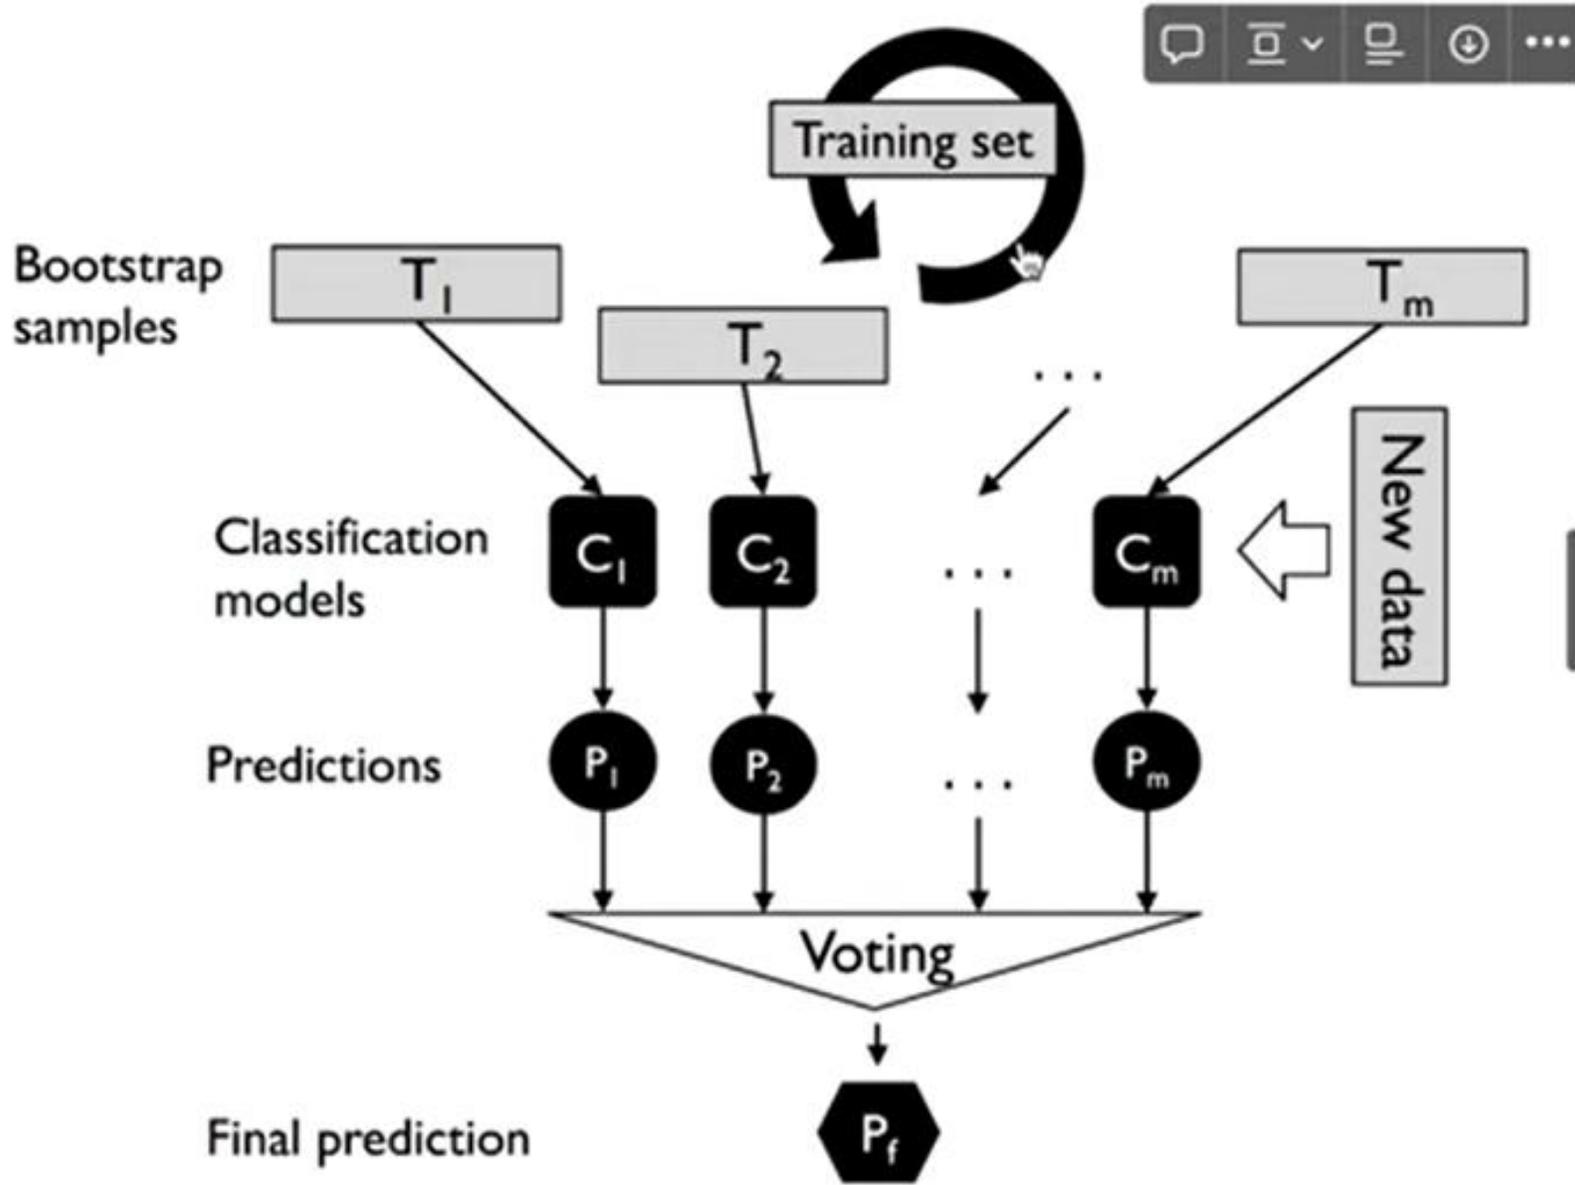
Chia-Hui Liu ^{1,2,†}, Cheng-Jyun Lin ^{3,†}, Ya-Han Hu ^{2,4} and Zi-Hung You ^{5,*} 

dental implants at the case hospital for a total of **8 categories** and **20 variables**. Supervised learning techniques such as **decision tree (DT)**, **support vector machines**, **logistic regressions**, and **classifier ensembles (i.e., Bagging and AdaBoost)** were used to analyze the prediction of the failure of dental implants. The results show that **DT with both Bagging** and **Adaboost** techniques possesses the highest prediction performance for the failure of dental implant (area under the receiver operating characteristic curve, AUC: 0.741); the analysis also revealed that the **implant systems affect dental implant failure**. The model can help clinical surgeons to reduce medical failures by choosing the

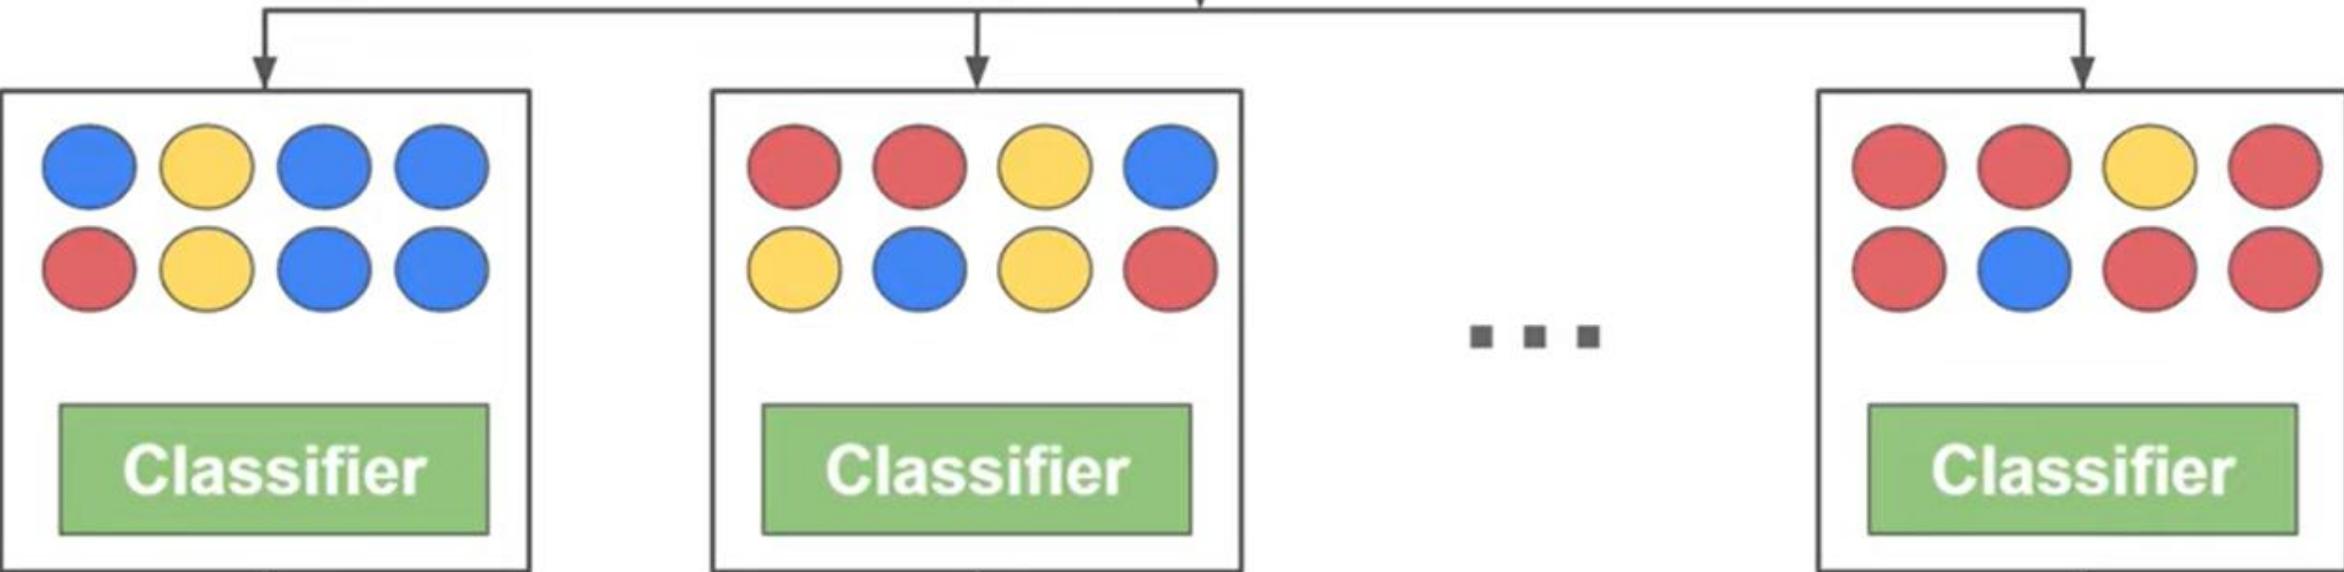
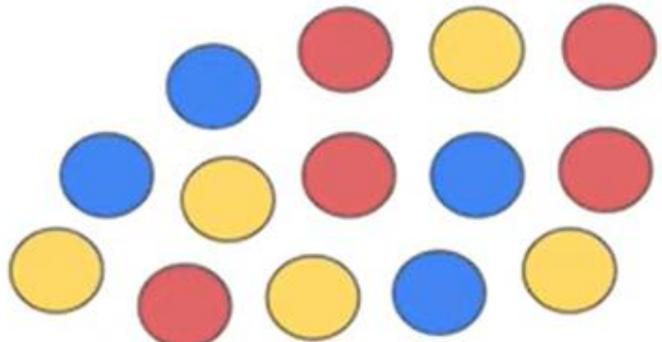
H Implant attributes
2

Implant system

- 0: Straumann[®]
- 1: Ankylos[®]
- 2: XIVE[®]
- 3: Nobeactive[®]
- 4: Branemark[®]
- 5: Lifecore[®]



Bagging

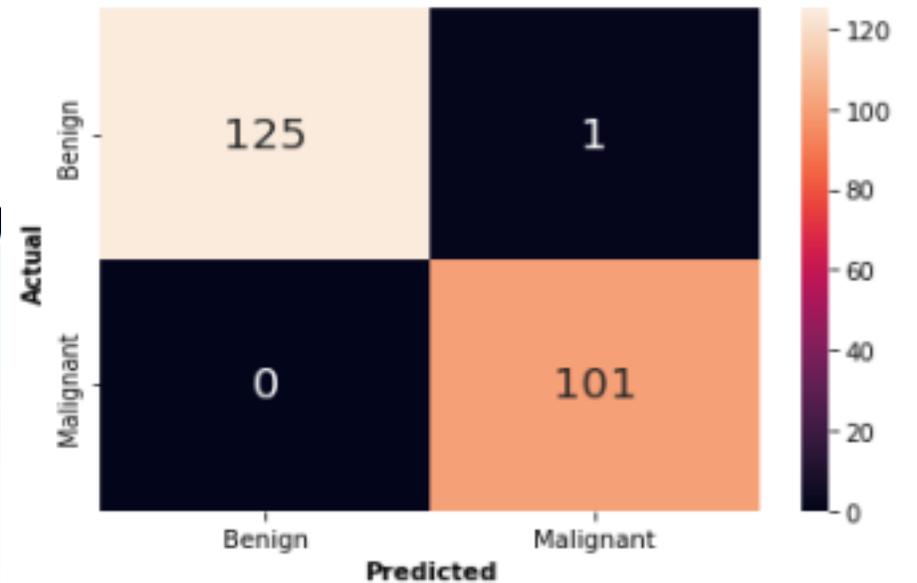


Kỹ thuật Boosting (XGBoost, Gradient Boost)

- Các cây được xây dựng tuần tự. Cây sau tập trung sửa lỗi cho cây trước đó bằng cách tăng trọng số cho các mẫu dữ liệu khó phân loại.
- **Đặc điểm:** Độ chính xác cực cao nhưng cần tinh chỉnh kỹ.
- **Ứng dụng nha khoa:**
 - Sàng lọc sớm ung thư khoang miệng từ các biểu hiện lâm sàng nhỏ nhất.

Classification of Oral Cancer Into Pre-Cancerous Stages From White Light Images Using LightGBM Algorithm

BIBEK GOSWAMI¹, M. K. BHUYAN¹, (Senior Member, IEEE), SU



stages, successively leading to a significant decrease in the mortality rate. In this work, a method is proposed that can effectively differentiate between **benign** and **malignant** oral cavity lesions and also classify their pre-cancerous stages. The method involves exploring **five distinct color spaces** and **extracting color and texture features**, which are then classified using a machine learning technique called **Light Gradient Boosting Machine (LightGBM)**. The overall performance is promising, outperforming the state-of-art methods for the task of oral cancer classification, with a testing accuracy of 99.25%, **precision of 99.18%**, **recall of 99.31%**, **f1-score of 99.24%** and specificity of 99.31% for the binary classification, and testing accuracy of

Root): độ tương quan màu sắc (GLCM_corr)

Các bước tiếp theo: Độ đồng nhất (Homogen) và độ tương phản (Contrast) của vùng niêm mạc miệng.

Mô ung thư thường có cấu trúc hỗn loạn, độ tương phản cao và độ đồng nhất thấp

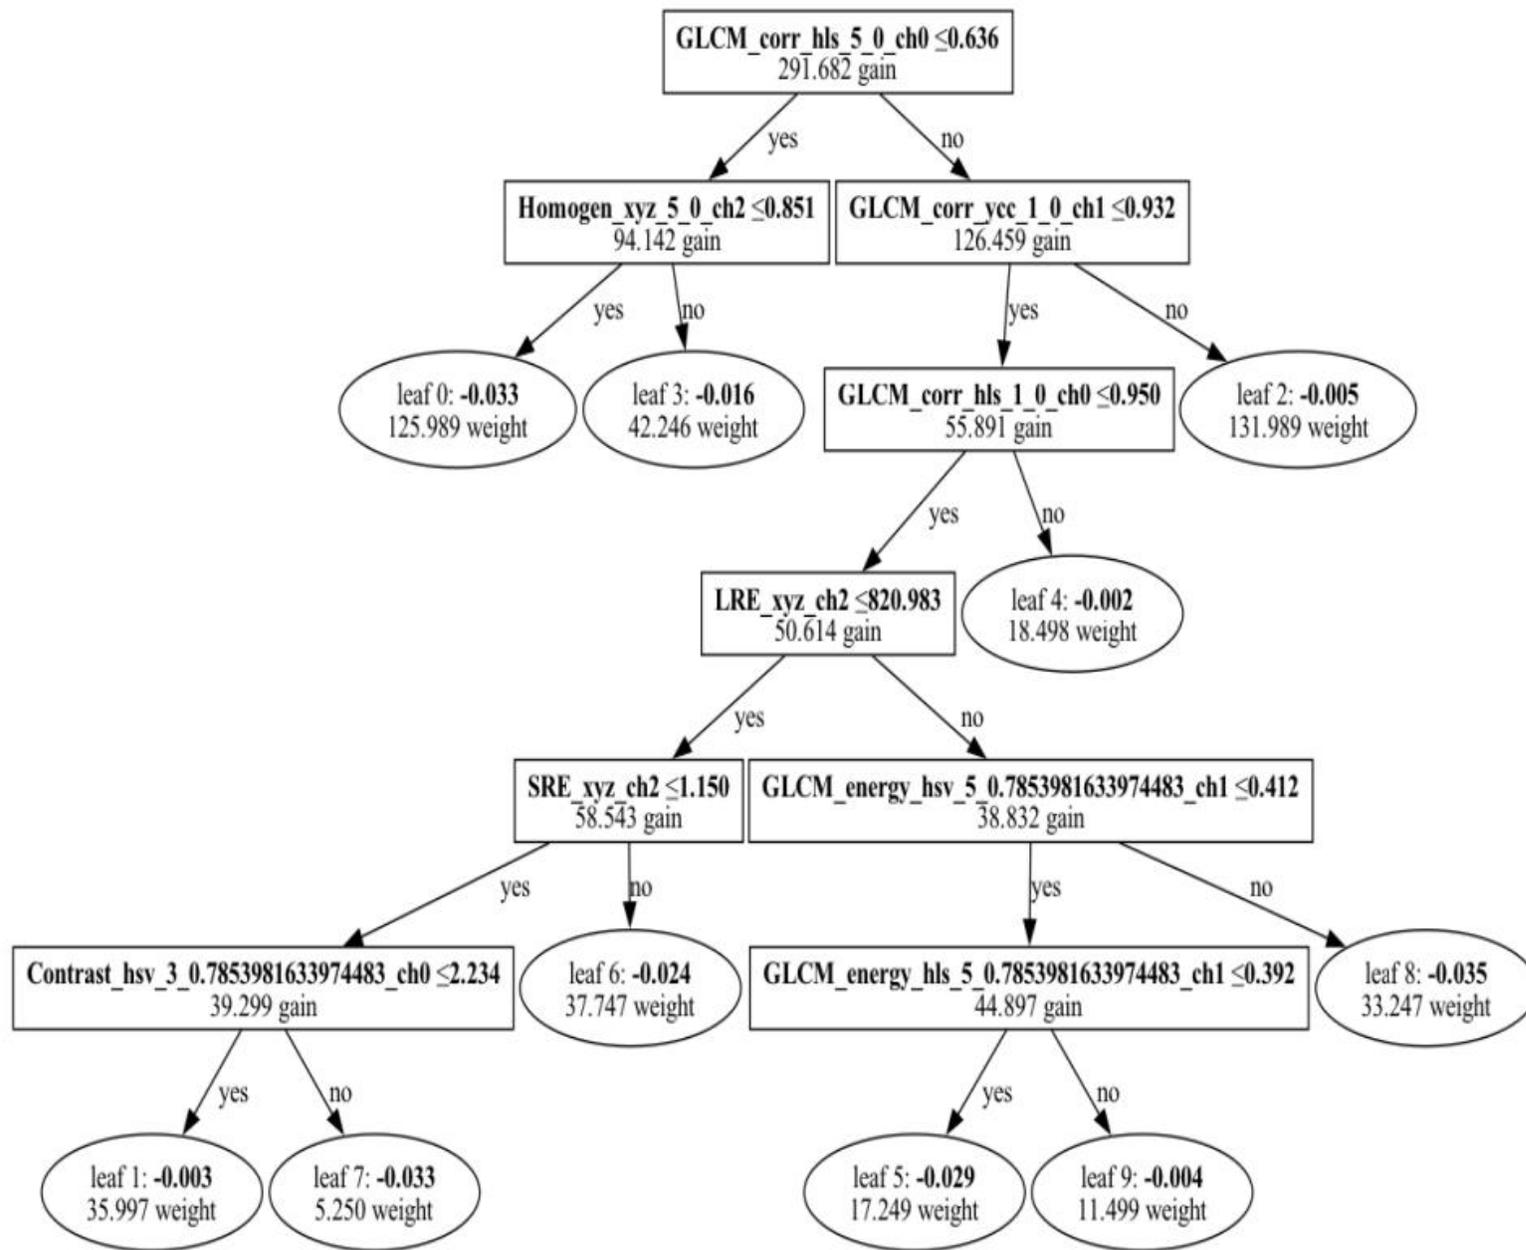
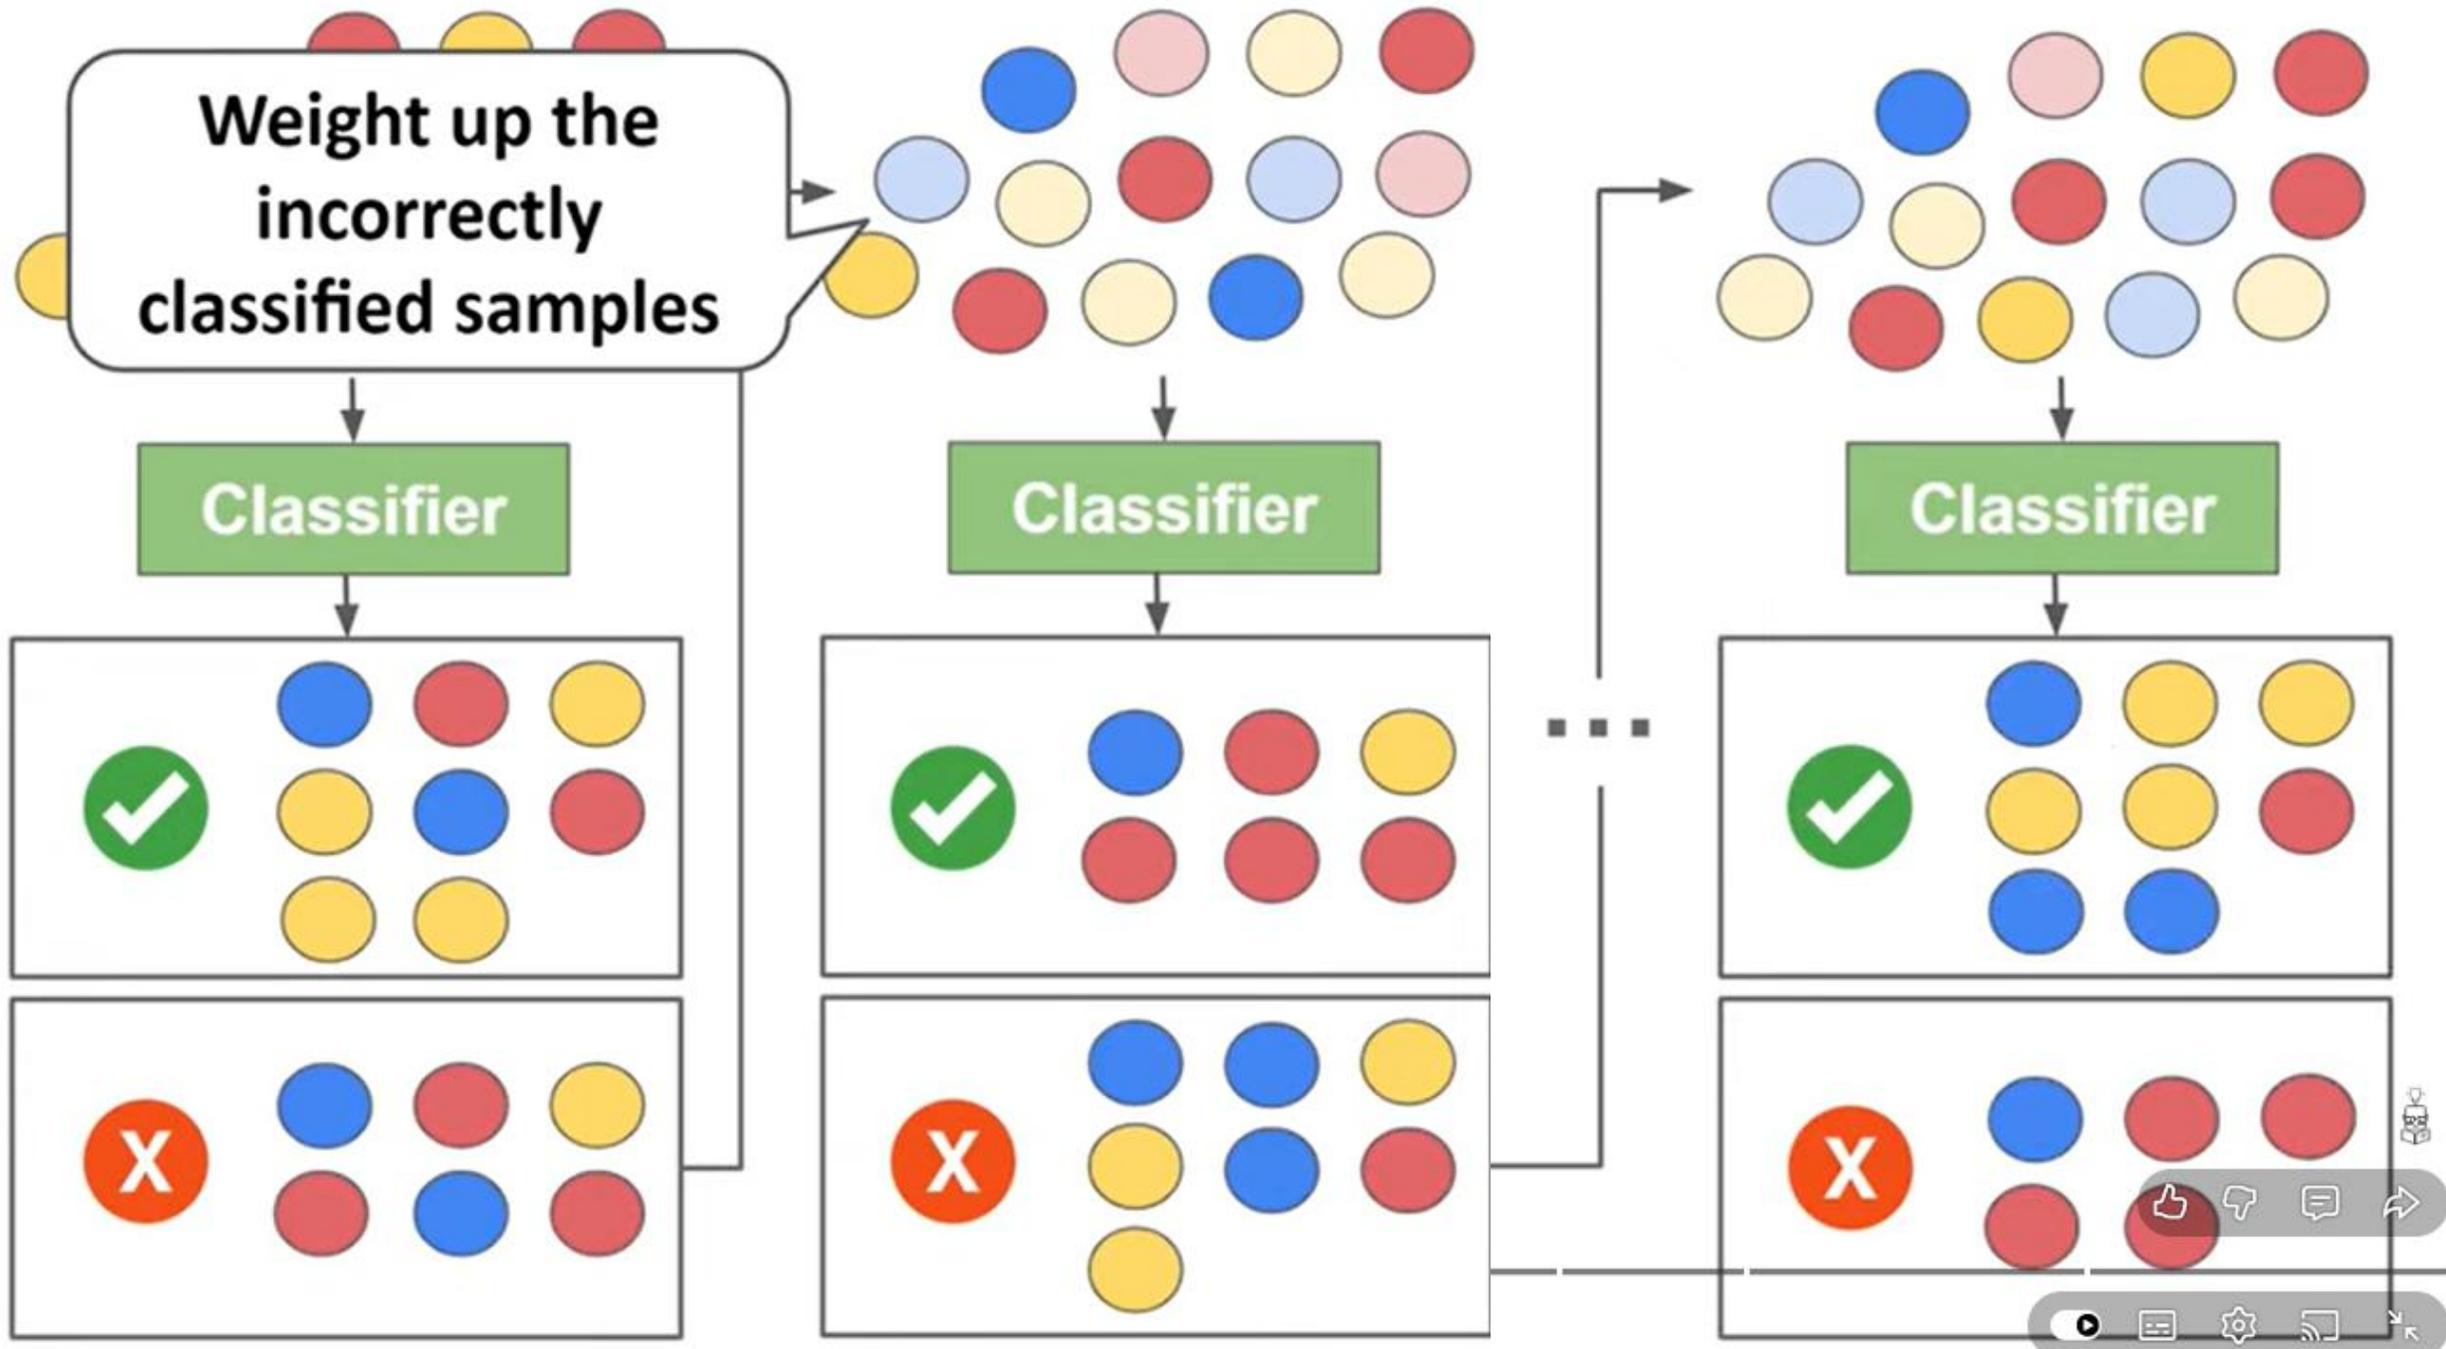
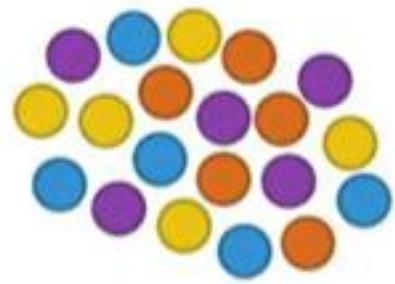
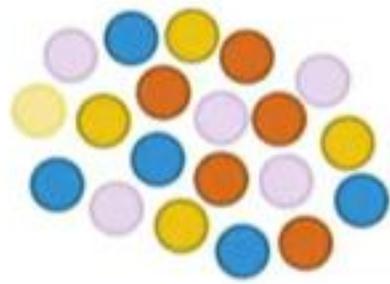


FIGURE 10. Decision tree of fifth iteration for binary classification.

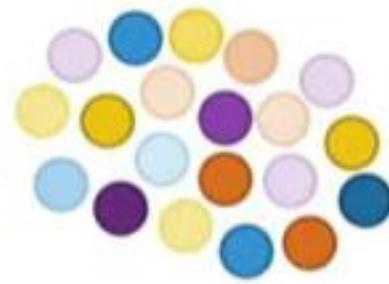




Original Data



Weighted data



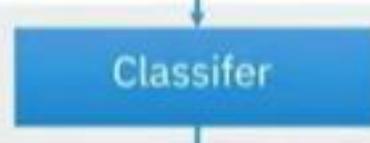
Weighted data



Classifier

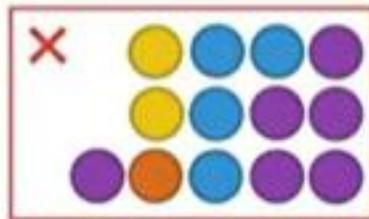
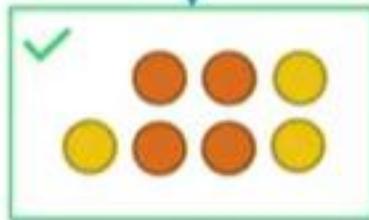
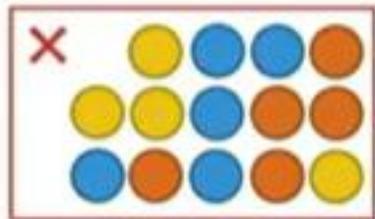
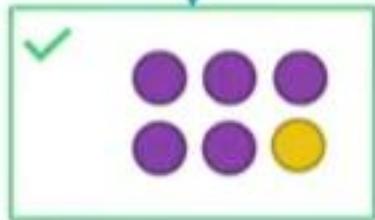


Classifier

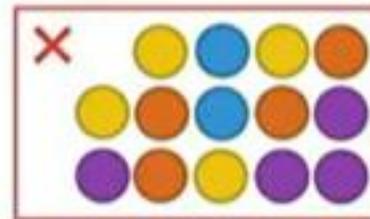
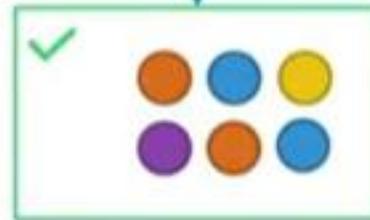


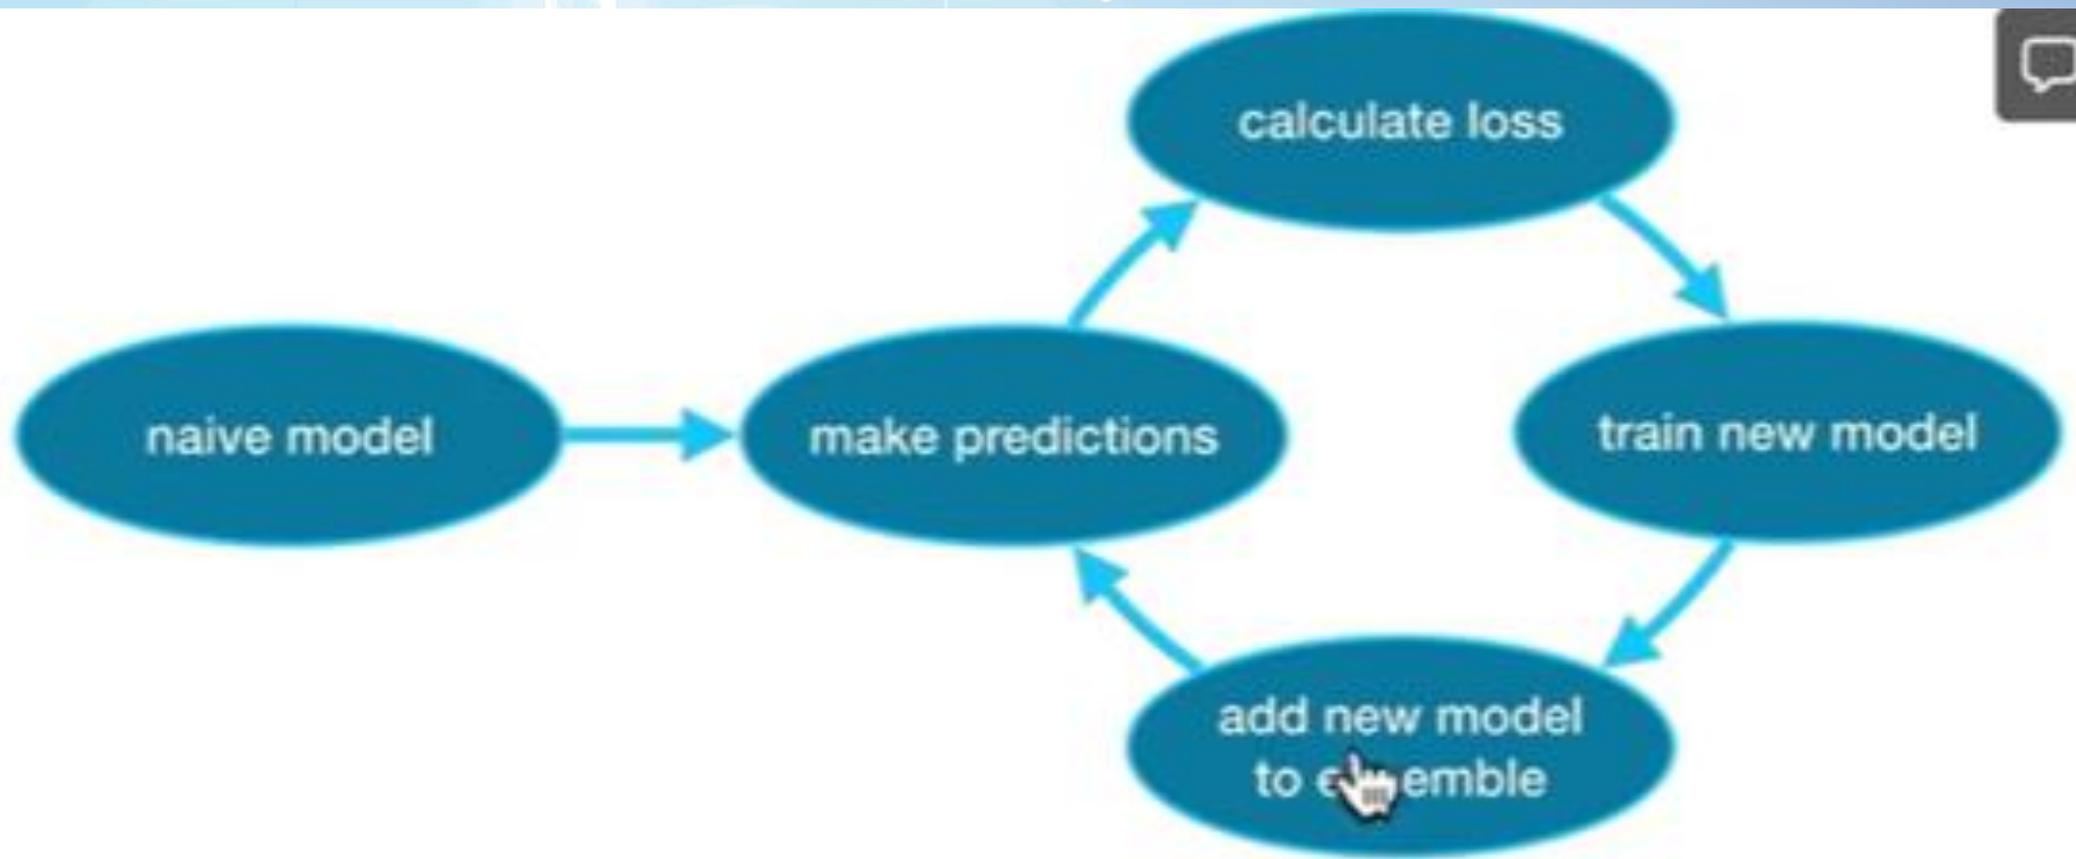
Classifier

Ensemble
Classifier



...





Source: <https://www.kaggle.com/code/alexisbcook/xgboost>

Kỹ thuật Stacking

- **Cơ chế:** Thay vì dùng các cây giống nhau, Stacking kết hợp các mô hình khác loại (ví dụ: kết hợp Decision Tree + SVM + Neural Network). Một mô hình "Meta-learner" sẽ học cách tổng hợp kết quả từ các mô hình này.
- **Ứng dụng nha khoa:**
- Để tiên đoán nguy cơ sâu răng có thể kết hợp k-nearest neighbors (KNN) và logistic regression (LR) hay KNN+LR+MLP

Development and evaluation of a multi-model stacking approach for caries risk assessment in adults using supervised machine learning

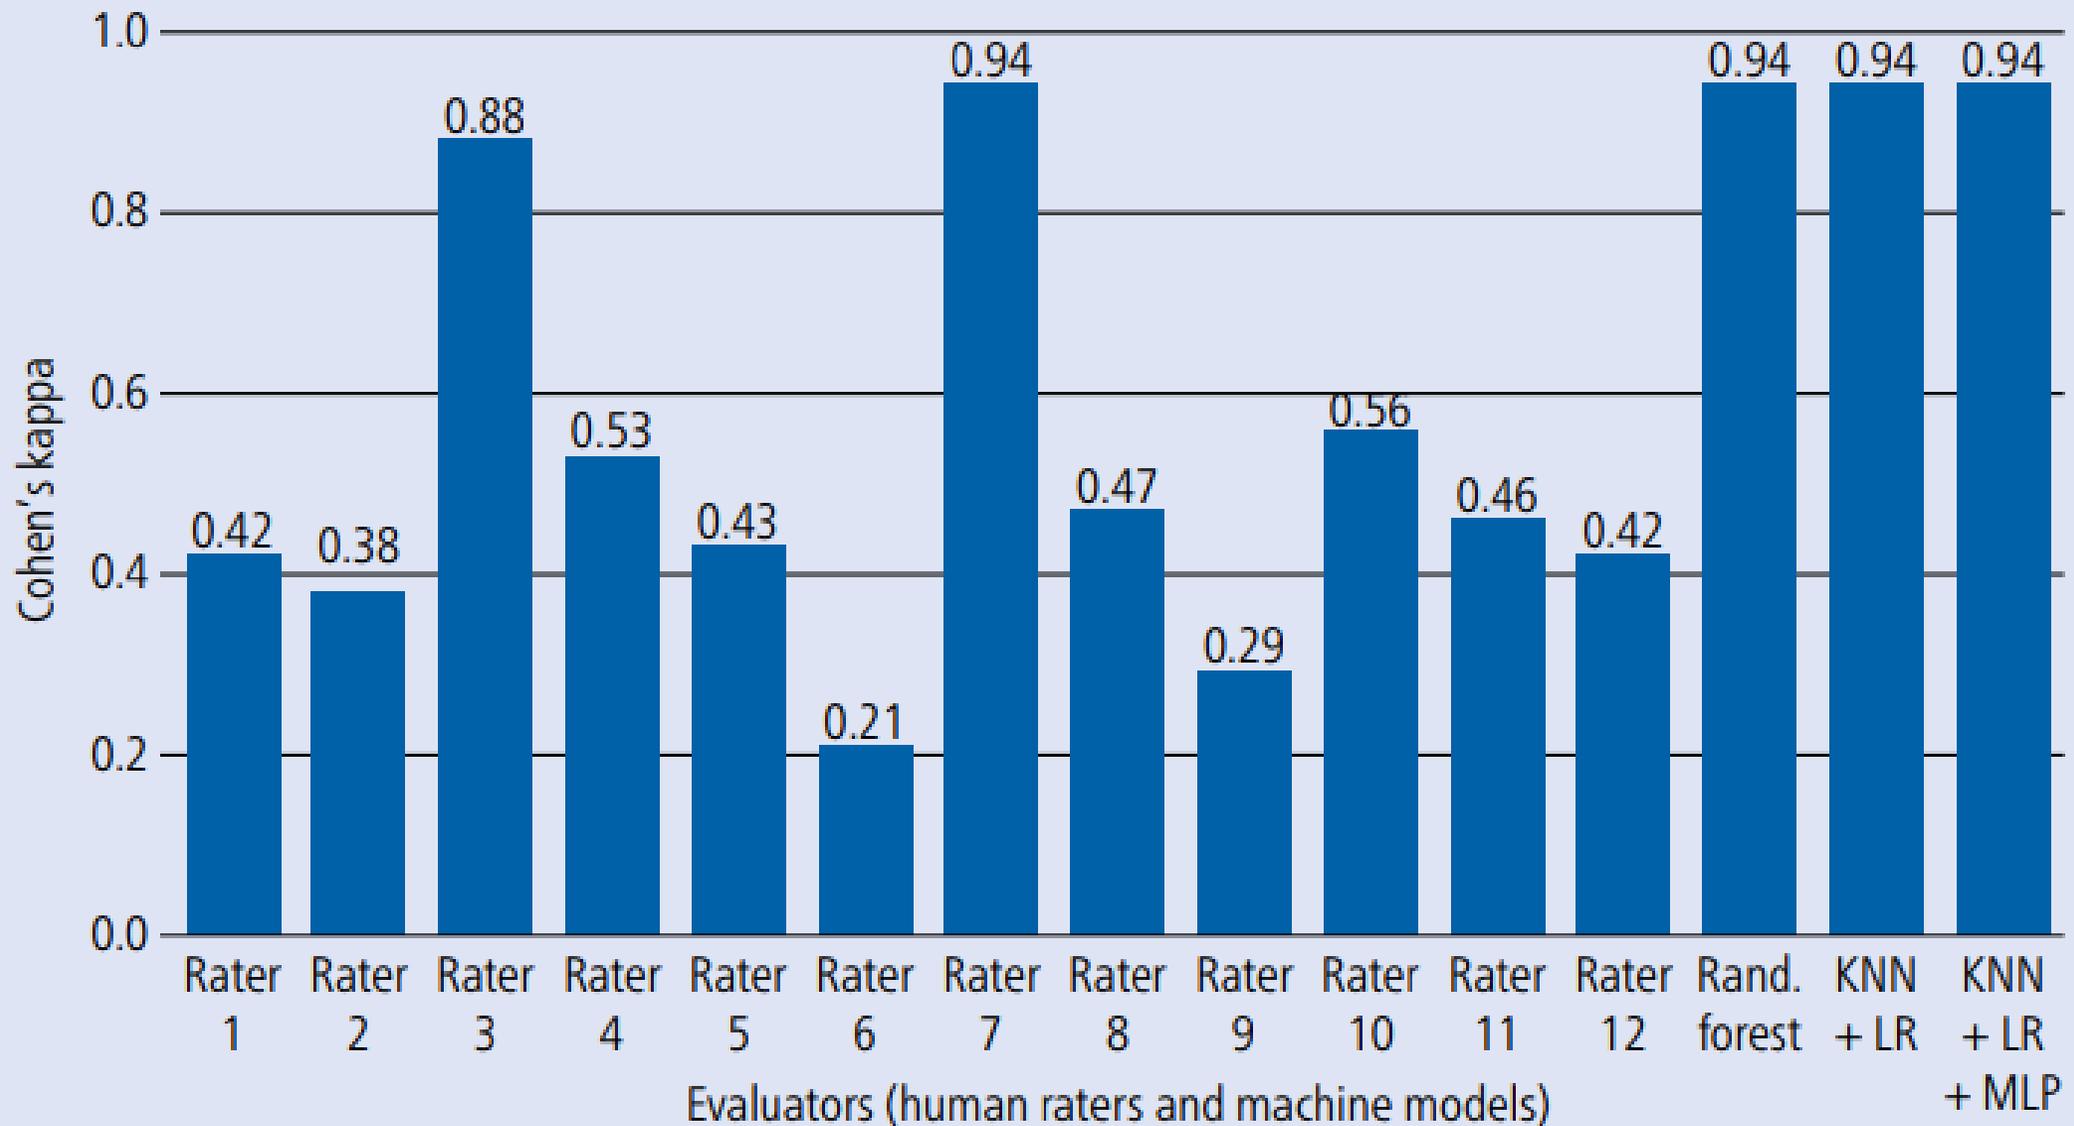
Mohd Hidir Mohd Atni,^{1,2} Nik Mohd Mazuan Nik Mohd Rosdy,³ Mohd Azrul Amir M Rusly,⁴ Noor Asilati Abdul Raob^{1,2} and Budi Aslinie Md Sabri*¹

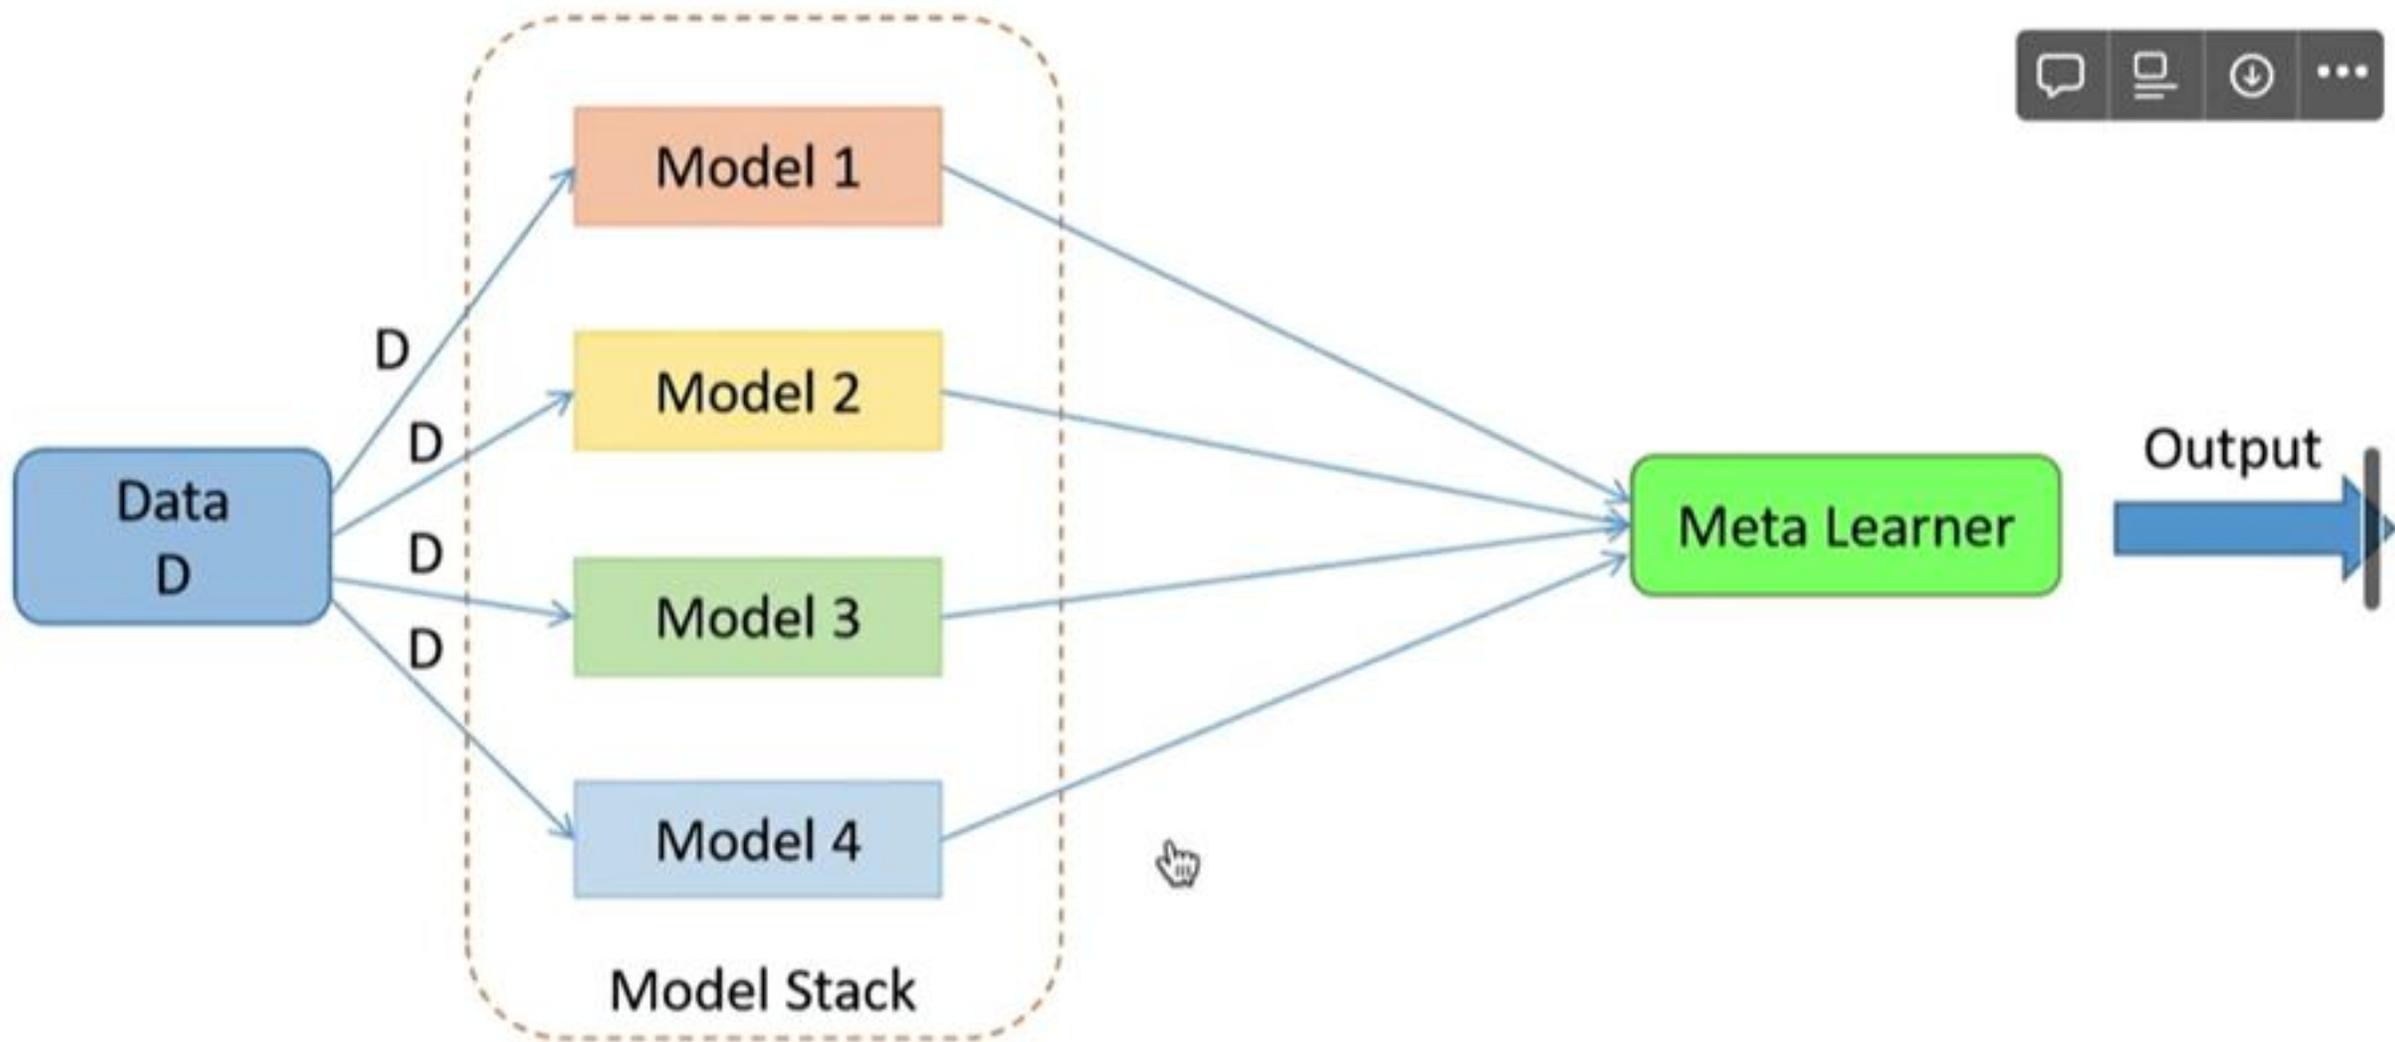
A random selection of 25 test cases was discussed and classified by four senior dental public health lecturers, establishing a gold standard benchmark. The three most

Table 2 Performance metrics of optimised machine learning models

Model	K-fold	Accuracy (95% CI)
KNN + LR	2	0.9517 (0.9517–0.9517)
KNN + LR + MLP	2	0.9363 (0.9363–0.9363)
Random forest	17	0.9047 (0.9043–0.9052)
Extreme gradient boosting	17	0.9020 (0.8918–0.9122)
Decision tree	3	0.8715 (0.8671–0.8760)

Fig. 2 Cohen's kappa agreement for human raters and machine models against benchmark





Credit: [Yash Khandelwal](https://www.analyticsvidhya.com/blog/2021/08/ensemble-stacking-for-machine-learning-and-deep-learning/), <https://www.analyticsvidhya.com/blog/2021/08/ensemble-stacking-for-machine-learning-and-deep-learning/>

Deep learning (DL)

DL is a sub-field of ML, characterized by the use of **neural networks** that mimic the structure and function of biological neural networks [26]. It is **less transparent** than ML and automatically selects features from the raw data. Training of the algorithm can be either **supervised** or **unsupervised** and occurs with or without labelled input data, respectively [29]. DL is often seen as a 'black box'

Detection of patient-ventilator asynchrony from mechanical ventilation waveforms using a **two-layer long short-term memory neural network**

Lingwei Zhang^{a,1}, Kedong Mao^{a,1}, Kailiang Duan^b, Siqi Fang^c, Yunfei Lu^a, Qiang Gong^a,



ELSEVIER

Detection of patient-ventilator asynchrony from mechanical ventilation waveforms using a **two-layer long short-term memory neural network**

Lingwei Zhang^{a,1}, Kedong Mao^{a,1}, Kailiang Duan^b, Siqi Fang^c, Yunfei Lu^a, Qiang Gong^a,

Background and objective: Mismatch between invasive mechanical ventilation and the requirements of patients results in **patient-ventilator asynchrony (PVA)**, which is associated with a series of adverse clinical outcomes. Although the efficiency of the available approaches for automatically detecting various types of PVA from the ventilator waveforms is unsatisfactory, the feasibility of powerful **deep learning** approaches in addressing this problem has not been investigated.

Methods: We propose a 2-layer long short-term memory (LSTM) network to detect two most frequently encountered types of PVA, namely, **double triggering (DT)** and **ineffective inspiratory effort during expiration (IEE)**, on two datasets. The performance of the networks is evaluated first using cross-validation on the combined dataset, and then using a cross testing scheme, in which the LSTM networks are established on one dataset and

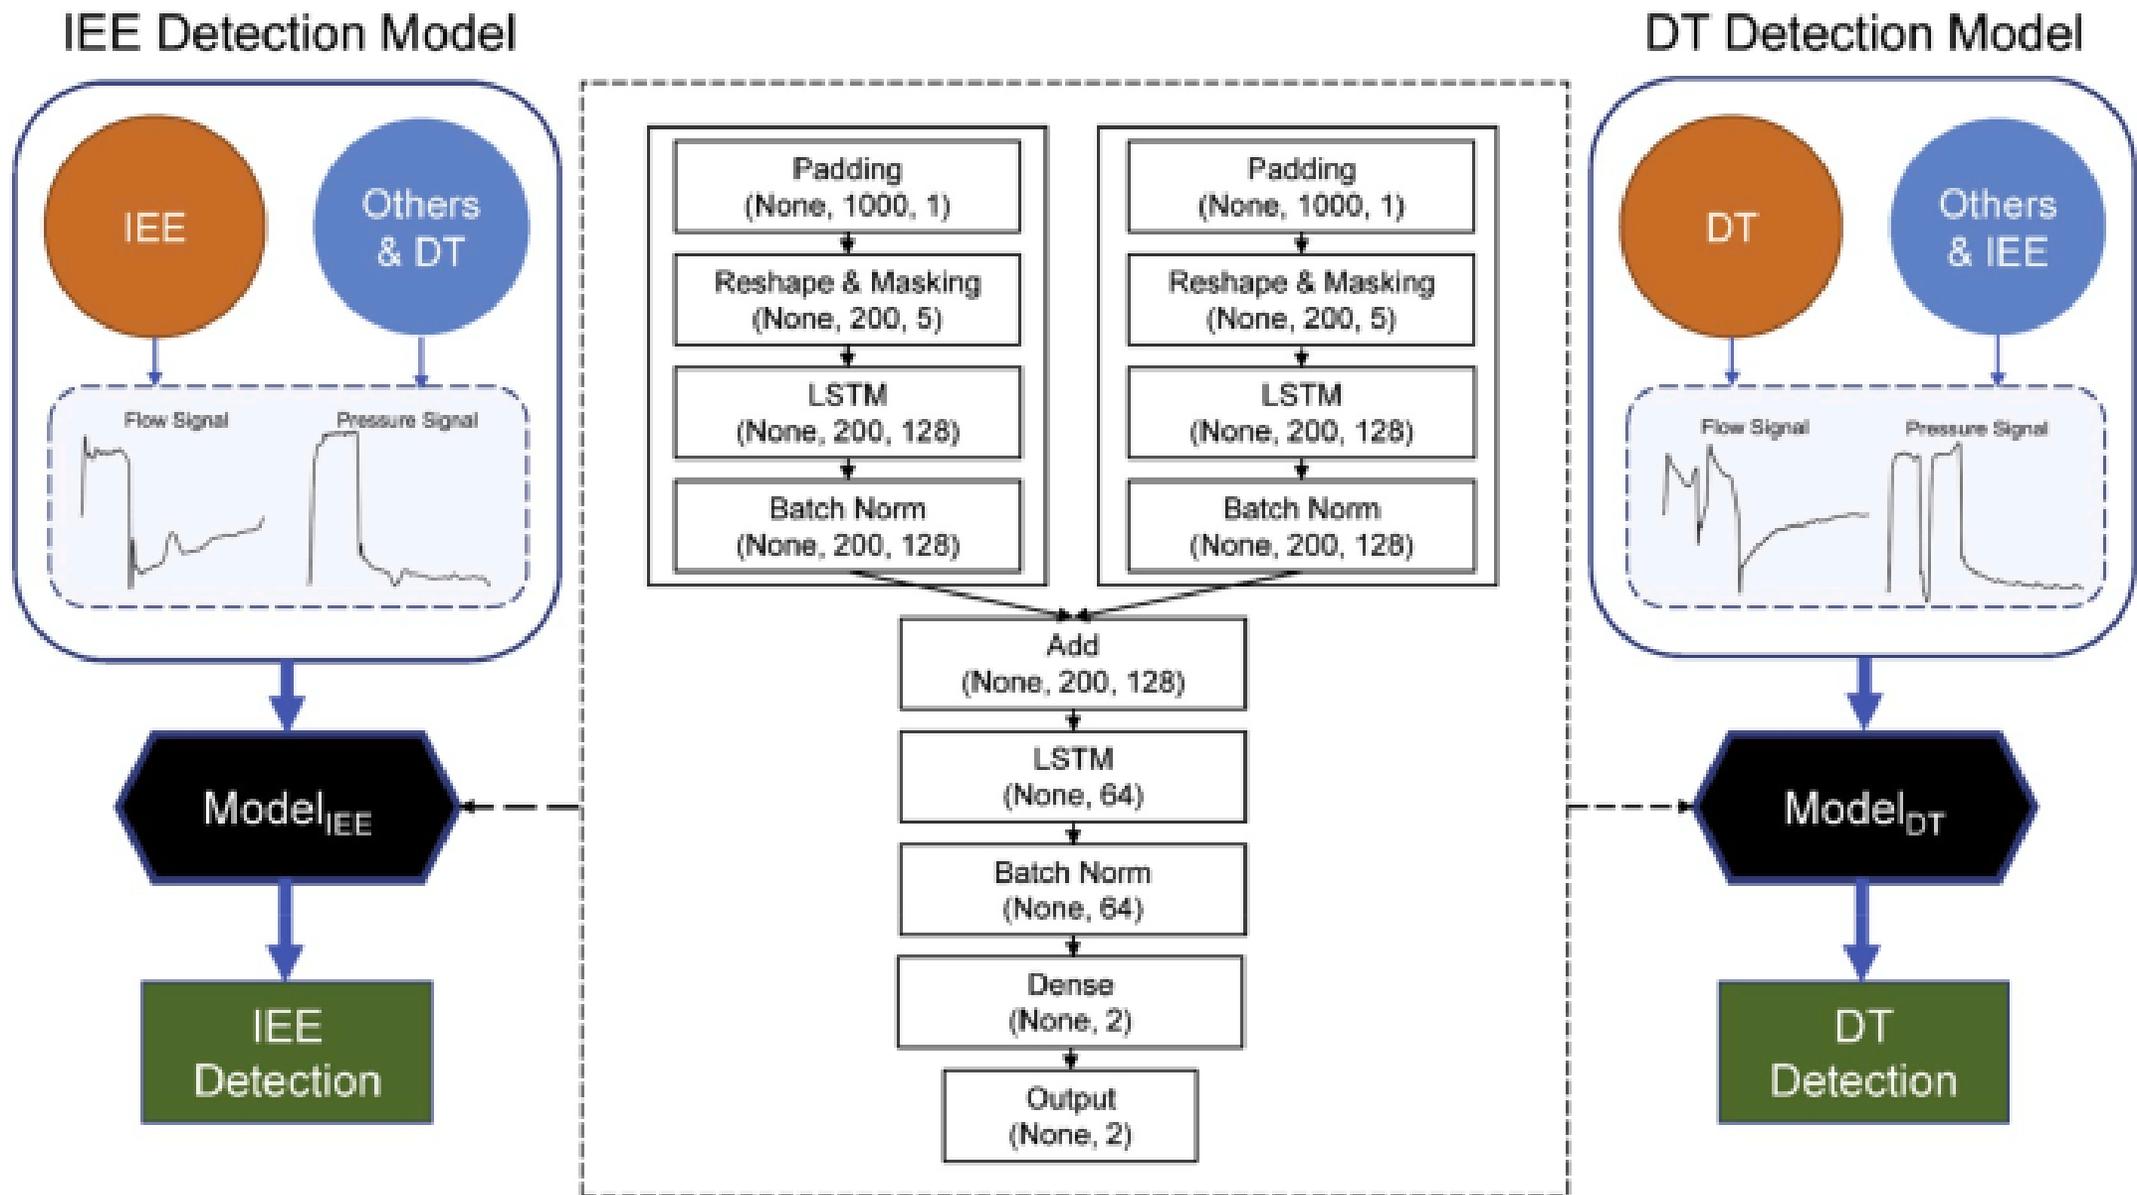


Fig. 5. Architecture of the proposed 2-layer LSTM network.

AI-enabled respiratory healthcare

In-person

- Regular/specialist consultation
- Inhaler technique training
- Patient triage

C1



C2



Current

F2



F1

Environmental data

- Remote clinician monitoring
- AI CDSS for patients' stratification/diagnosis
- Automatic symptom detection supported by smart device (e.g. digital stethoscope, smart inhaler, smart peak flow meter)
- AI supported self-management and diagnosis
- Immersive learning, inhaler checking, psychological/social support and rehabilitation (augmented reality), virtual reality, mixed reality and extended reality
- Virtual ward
- Remote consultation

Current

C3



Future

F3



Electronic health





Chẩn đoán Hình ảnh (Imaging Diagnostics)

- **Phân tích X-quang và CT ngực:**

- **Phát hiện nốt phổi/u phổi:** Tăng độ nhạy và tốc độ so với bác sĩ.
- **Đánh giá mức độ tổn thương phổi (ví dụ: viêm phổi, xơ phổi, COVID-19):** Phân vùng tổn thương tự động.



Chẩn đoán và Tiên lượng Bệnh Hô hấp

- **Chẩn đoán Bệnh Phổi Tắc nghẽn Mạn tính (COPD) và Hen suyễn:** Phân tích dữ liệu Phế dung ký (Spirometry) và Hồ sơ bệnh án điện tử (EHR) để xác định các kiểu hình (phenotypes) phức tạp.
- **Dự đoán đợt cấp:** Sử dụng dữ liệu cảm biến (wearables) và môi trường để dự đoán nguy cơ nhập viện.



Cá nhân hóa Điều trị (Personalized Medicine)

- **Ung thư Phổi:** Phân tích hình ảnh, gen, mô bệnh học để **dự đoán** đáp ứng với điều trị đích (**Targeted Therapy**) và liệu pháp miễn dịch (**Immunotherapy**).
- **Chọn liều/phác đồ tối ưu:** Dựa trên dữ liệu bệnh nhân thực tế.

NỘI DUNG CHÍNH

- 1 Ứng dụng Hiện tại của AI trong Hồ hấp**
- 2 Thách thức và Hạn chế**
- 3 Định hướng Tương lai cho Hội Hồ hấp TP HCM**

Thách thức và Hạn chế (1)

- **Dữ liệu:** Thiếu bộ dữ liệu lớn, chất lượng cao, đã được chú thích (annotated data) và **đặc biệt là dữ liệu từ Việt Nam.**
- **Tính pháp lý và Đạo đức:**
 - Trách nhiệm khi có sai sót chẩn đoán của AI (Accountability).
 - Bảo mật và Quyền riêng tư của dữ liệu bệnh nhân.

Thách thức và Hạn chế (2)

- **Hạ tầng và Nguồn nhân lực:** Thiếu chuyên gia "cầu nối" (Bridge Scientists) vừa hiểu lâm sàng, vừa giỏi về AI/Data Science.
- **Tính chấp nhận (Acceptance):** Sự e ngại của một số bác sĩ lâm sàng đối với công nghệ mới.

NỘI DUNG CHÍNH

1 Ứng dụng Hiện tại của AI trong Hồ hấp

2 Thách thức và Hạn chế

3 Định hướng Tương lai cho Hội Hồ hấp TP HCM

Định hướng Tương lai cho Hội Hồ hấp TP HCM

- Xây dựng Hệ sinh thái Dữ liệu Hồ hấp Quốc gia/Vùng
- Đào tạo và Phát triển Nguồn nhân lực Chuyên sâu
- Thúc đẩy Nghiên cứu và Phát triển AI "Made in Vietnam"
- Đề xuất Khung pháp lý và Đạo đức

Xây dựng Hệ sinh thái Dữ liệu Hồ hấp Quốc gia/Vùng

- **Tiêu chuẩn hóa Dữ liệu:** Hợp tác với Bộ Y tế và các bệnh viện để xây dựng tiêu chuẩn lưu trữ và trao đổi dữ liệu y tế (ví dụ: FHIR) trong lĩnh vực hồ hấp.
- **Kho Dữ liệu Chia sẻ (Data Repository):** Hội đóng vai trò trung gian, tạo ra một kho dữ liệu phi danh tính, bảo mật, phục vụ nghiên cứu và phát triển AI.

Đào tạo và Phát triển Nguồn nhân lực Chuyên sâu

- **Chương trình Đào tạo Liên ngành:** Phối hợp với các trường đại học/Viện nghiên cứu (ĐH Bách Khoa, ĐH Công nghệ Thông tin) mở các khóa học về "**AI cho Bác sĩ Hô hấp**" và "**Ứng dụng Lâm sàng của AI**".
- **Khuyến khích "Bridge Scientists":** Hỗ trợ các nghiên cứu sinh, bác sĩ trẻ theo đuổi lĩnh vực giao thoa.

. Thúc đẩy Nghiên cứu và Phát triển AI "Made in Vietnam"

- **Tổ chức Cuộc thi/Giải thưởng AI:** Phát động các cuộc thi giải quyết các bài toán hô hấp thực tế của Việt Nam (ví dụ: chẩn đoán bệnh lao, phân tích phổ dung ký theo chuẩn người Việt).
- **Phòng Lab Nghiên cứu Ảo:** Tạo nền tảng hợp tác nghiên cứu giữa các bệnh viện trong thành phố/vùng.



Đề xuất Khung pháp lý và Đạo đức

- Hội tham gia vào quá trình tư vấn cho cơ quan quản lý (ví dụ: Sở Y tế, Bộ Y tế) về các quy định thử nghiệm và triển khai các sản phẩm AI y tế.
- Xây dựng "**Bộ Quy tắc Đạo đức AI**" riêng cho lĩnh vực Hồ hấp.

Kết luận: Tầm nhìn cho tương lai

- **Tóm tắt Lợi ích:** AI là chìa khóa để đạt được **3 mục tiêu chính: Tăng độ chính xác, Cá nhân hóa điều trị và Quản lý bệnh mạn tính từ xa.**
- **Lời kêu gọi Hành động:** Hội Hô hấp TPHCM cần là **đơn vị tiên phong**, chuyển từ ứng dụng sang **sở hữu và phát triển** công nghệ AI.
- **Thông điệp cuối cùng:** Tương lai của ngành hô hấp là sự cộng tác chặt chẽ giữa **Trí tuệ Bác sĩ (Human Intelligence)** và **Trí tuệ Nhân tạo (AI)**.



HỘI HỒ HẤP
THÀNH PHỐ HỒ CHÍ MINH

HỘI NGHỊ THƯỜNG NIÊN HỘI HỒ HẤP - HRS 2026
THE ANNUAL CONFERENCE OF THE HO CHI MINH RESPIRATORY SOCIETY

CẢM ƠN QUÝ ĐỒNG NGHIỆP ĐÃ CHÚ Ý LẮNG NGHE

VŨNG TÀU, TP.HCM - NGÀY 21 THÁNG 3 NĂM 2026