

Áp dụng mạng Bayes xây dựng mô hình dự đoán xác suất có điều kiện phức hợp

Applying Bayesian network to build predicting model for complex conditional probabilities

Đặng Việt Hùng^{a*}, Trần Nhật Vinh^a, Nguyễn Dũng^a, Võ Nhân Văn^a, Nguyễn Thị Thanh^b
Nguyễn Quang Vinh^c

Dang Viet Hung^{a*}, Tran Nhat Vinh^a, Nguyen Dung^a, Vo Nhan Van^a, Nguyen Thi Thanh^b,
Nguyen Quang Vinh^c

^aKhoa Công nghệ Thông tin, Trường Khoa học Máy tính, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

^aFaculty of Information Technology, School of Computer Science, Duy Tan University, 550000, Da Nang, Vietnam

^bKhoa Giáo dục Nghề nghiệp, Trường Cao đẳng Sư Phạm Quảng Trị, Quảng Trị, Việt Nam

^bFaculty of Career Education, Quang Tri Teacher Training College, Quang Tri, Vietnam

^cTổng Công ty Điện lực Thành phố Hồ Chí Minh, Thành phố Hồ Chí Minh, Việt Nam

^cHo Chi Minh city Power Corporation, 700000 Ho Chi Minh city, Vietnam

(Ngày nhận bài: 05/01/2024, ngày phản biện xong: 09/03/2024, ngày chấp nhận đăng: 26/03/2024)

Tóm tắt

Các giải pháp Học máy nhằm hỗ trợ ra quyết định càng ngày càng được hoàn thiện với sự phát triển của các mạng học sâu. Tuy nhiên, các mạng này chỉ hoạt động chính xác khi vector dữ liệu đầu vào là đầy đủ. Đối với dữ liệu không đầy đủ, các mô hình xác suất có điều kiện trở nên hữu dụng hơn các mạng học sâu. Bài báo này sẽ giới thiệu mạng Bayes - một giải pháp sơ cấp để dự đoán xác suất trong các điều kiện phức hợp, làm tiền đề cho ứng dụng thứ cấp là phân loại, dự đoán hay ra quyết định. Mạng Bayes cũng được huấn luyện dựa trên dữ liệu đầu vào, qua đó xác định được sự phụ thuộc hay độc lập của các trường dữ liệu. Bài báo sẽ sử dụng dữ liệu về hoàn cảnh sinh viên nhằm ước lượng các xác suất liên hệ giữa các trường hoàn cảnh và khả năng bỏ học của sinh viên.

Từ khóa: Học máy; mạng Bayes; xác suất có điều kiện.

Abstract

Machine learning solutions for decision support are increasingly being refined with the development of deep learning networks. However, these networks only work correctly when the input data vector is complete. For incomplete data, conditional probability models become more useful than deep learning networks. This article will introduce the Bayesian network, which is a primary solution for predicting probabilities in complex conditions, acting as a premise for secondary applications such as classification, prediction or decision-making processes. The Bayesian network is also trained based on input data, determining the dependence or independence of data fields. The article will use data on students to estimate the related probabilities between their circumstances and their likelihood of dropping out.

Keywords: Machine learning; mạng Bayes; conditional probability.

*Tác giả liên hệ: Đặng Việt Hùng

Email: dangviethung@duytan.edu.vn

1. Giới thiệu

Là một phần của Trí tuệ nhân tạo, Học máy nghiên cứu cách thức một hệ thống tính toán có thể tiếp nhận tri thức thông qua dữ liệu và kinh nghiệm tự thu thập. Điều này cho phép máy móc có thể học được các quan hệ giữa 2 tập vector dữ liệu: tập input và tập output, trong đó mỗi tập liên quan đến một số trường dữ liệu xác định nào đó. Các phương pháp từ đơn giản như K-láng giềng gần nhất (KNN), Hồi quy tuyến tính (Linear Regression) đến phức tạp như máy vector hỗ trợ (SVM), mạng Nơ-ron nhân tạo (ANN), v.v... đều có thể học được quan hệ này. Tuy nhiên, các giải pháp này cần phải có một bước tiền xử lý dữ liệu và trích xuất đặc trưng phức tạp. Khi các dẫn xuất học sâu (DNN) của ANN ra đời, dữ liệu chỉ cần một bước tiền xử lý đơn giản hơn là chuẩn hóa, hoặc vector hóa trước khi đưa vào huấn luyện mạng học sâu. Nguyên nhân là mạng học sâu có các cấu trúc phân tích như tích chập, truy hồi, ô nhớ, ô trạng thái, v.v... Các cấu trúc này có khả năng tự động tìm các đặc trưng phù hợp với bài toán. Mặc dù các mạng học sâu hiện nay giải quyết được đa số các vấn đề phức tạp và lớn, nhưng đối với những bài toán có dữ liệu vừa phải và không đầy đủ, mạng không thể thực hiện học và ra quyết định được. Trong các lớp giải pháp của Học máy vẫn tồn tại một số phương pháp có thể đối mặt với vấn đề này, cụ thể là Cây quyết định, Rừng ngẫu nhiên hay mạng Bayes [1], [2], [3], [4]. Các phương pháp này chủ yếu tìm các quan hệ xác suất giữa các trường dữ liệu đầu vào, trong đó dữ liệu đầu vào (dành cho cả huấn luyện và dự đoán) có thể thiếu một vài trường. Do đó, mặc dù là các phương pháp tiền thân của Học máy, chúng vẫn rất hữu dụng.

Bài báo này sẽ giới thiệu phương pháp suy luận xác suất bằng mạng Bayes khi cho trước một tổ hợp thông tin đã biết nào đó. Sau đó, bài báo sẽ sử dụng một phần thông tin thu thập về hoàn cảnh sinh viên, thực hiện xây dựng mô hình

tính toán các xác suất Bayes dành cho suy luận, trong đó hình thái, quan hệ và giá trị được xây dựng trực quan bằng chương trình Python.

2. Cơ sở lý thuyết

2.1. Công thức Bayes và mô hình đồ thị xác suất

Mạng Bayes được phát triển dựa trên lý thuyết mô hình đồ thị xác suất (graphical model) và công thức xác suất có điều kiện Bayes [1,3].

Giả sử A và B là hai sự kiện trong cùng một phép thử, ký hiệu $P(AB)$ như một xác suất kết hợp của sự kiện A và B , khi đó theo công thức xác suất có điều kiện ta có:

$$P(A|B) = \frac{P(AB)}{P(B)} \quad (1)$$

Bây giờ ta xét sự kiện A như một sự kiện không quan sát được và nó có thể xảy ra hoặc không xảy ra. B được xét như một sự kiện được quan sát [1]. Như vậy sự kiện B có thể xảy ra cùng với sự xuất hiện của sự kiện A hoặc phần bù của A . Công thức trên có thể viết lại như một quy tắc nhân:

$$P(AB) = P(B|A)P(A) = P(A|B)P(B) \quad (2)$$

Từ đó suy ra được công thức Bayes khi thay đổi vai trò của A và B trong công thức (2), ta được:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

Mô hình đồ thị xác suất [3] (PGM) là mô hình thống kê mã hóa các phân phối xác suất đa biến phức tạp bằng cách sử dụng đồ thị. Nói cách khác, PGM nếu được xây dựng thành công sẽ hiểu rõ các mối quan hệ độc lập có điều kiện giữa các biến ngẫu nhiên. Điều này khá hữu ích vì các kiến thức về đồ thị đã đạt được độ chín về lý thuyết, đặc biệt là về tách các tập con, nhóm và hàm trên đồ thị. Ngoài ra, người ta có thể dễ dàng hình dung với các PGM và có cái nhìn tổng quan

về cấu trúc mô hình. Tên đầy đủ của mô hình đồ thị là Probabilistic Graphical Model (PGM), do đó theo [5], mọi mô hình đồ thị đều gồm 2 phần:

- Phân đồ thị: thể hiện sự phụ thuộc giữa các biến ngẫu nhiên bằng đồ thị có hướng mà trong đó mỗi đỉnh là một biến ngẫu nhiên và mỗi cạnh có hướng từ A đến B thể hiện biến ngẫu nhiên B phụ thuộc biến ngẫu nhiên A. Dĩ nhiên đồ thị này không được có chu trình, hay còn được gọi là phi chu trình (Directed Acyclic Graph - DAG) [3].

- Phân xác suất: biểu diễn định lượng sự phụ thuộc này, với mỗi cạnh hoặc tập cạnh trong đồ thị, ta lưu phân phối xác suất có điều kiện tương ứng.

2.2. Mạng Bayes

Mạng Bayes là một dạng PGM, được phát triển đầu tiên vào những năm 1970 ở Đại học Stanford [2, 7]. Mạng Bayes là mô hình đồ thị thể hiện mối quan hệ nhân quả giữa các biến. Mạng Bayes chủ yếu dựa trên lý thuyết xác suất có điều kiện hay còn gọi là lý thuyết Bayes (Bayesian theory). Mạng Bayes kết hợp hài hòa giữa lý thuyết xác suất và lý thuyết đồ thị để giải quyết hai vấn đề quan trọng: Tính không chắc chắn và tính phức tạp, được ứng dụng rộng rãi trong toán học và kỹ thuật [6]. Cùng với các lý thuyết khác như Logic (Fuzzy Logic), mạng Noron nhân tạo v.v..., mạng Bayes là phương pháp chủ yếu dựa trên xác suất có điều kiện để dự báo hoặc chuẩn đoán một sự việc, một vấn đề đã, đang và sắp xảy ra.

Mạng Bayes được biểu diễn bằng đồ thị có hướng và không lặp (không tồn tại một chu trình khép kín trong đồ thị có hướng này, còn gọi là

phi chu trình), ký hiệu là G. Trong đó mỗi node của G là một biến ngẫu nhiên đại diện cho các thông tin hay feature chứa trong bài toán và các edge (cạnh) có hướng thể hiện sự ảnh hưởng giữa các node. Hay nói một cách khác đồ thị này chính là cách cấu trúc dữ liệu giúp biểu diễn xác suất hợp (joint distribution) của mô hình.

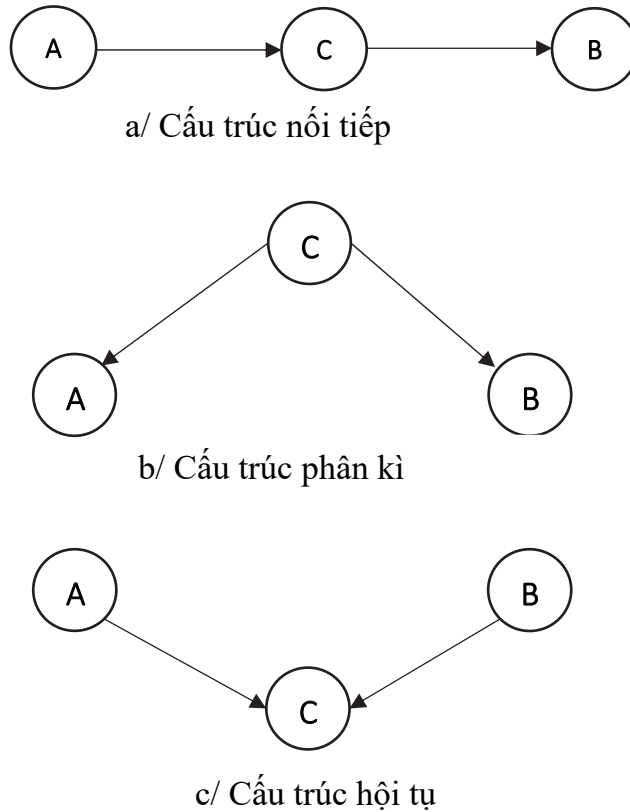
G là một mạng Bayes với các biến ngẫu nhiên X_1, \dots, X_n . Trong đó mỗi biến ngẫu nhiên X_i trong đồ thị G tương ứng với một node trong G được gán tương ứng với một factor. Trong trường hợp của BN factor tại mỗi node là Conditional Probability Distribution (CPD – phân phối xác suất có điều kiện) hay còn gọi là local probabilistic model. CPD của X_i là phân phối xác suất của biến X_i khi biến các giá trị các biến ngẫu nhiên là node cha của chúng (X_i có thể có nhiều hơn một cha – node thân hay node lá, hoặc không có node cha – node gốc). Mỗi CPD có thể được biểu diễn bằng các bảng, cấu trúc dạng cây (tree structure) hay noisy-OR, noisy-MAX.

2.3. Sự độc lập có điều kiện từ đồ thị

Khi phân rã một đồ thị phi chu trình để xét sự độc lập giữa các biến ngẫu nhiên, ta luôn gặp một trong những cấu trúc cơ bản gồm các liên kết hoặc nối tiếp, hoặc phân kì, hoặc hội tụ gồm ba biến ngẫu nhiên. Ba biến này gồm một biến điều kiện C (nằm giữa) và hai biến còn lại là hai biến cần xét sự độc lập A và B. Ta lần lượt xét các trường hợp cụ thể này như sau đây [2, 7]:

a/ Cấu trúc nối tiếp:

Với cấu trúc nối tiếp, nếu không có biến nào được quan sát thì:



Hình 1. Ba cấu trúc cơ bản sau khi phân rã một đồ thị xác suất.

$$P(AB) = P(A) \sum_C P(C|A)P(B|C) \quad (4)$$

$P(AB)$ do đó không khái quát thành $P(A)P(B)$. Vì vậy, $A \not\perp B | \phi$. Nghĩa là, nếu ta không biết thông tin gì về C thì A và B là phụ thuộc.

Tuy nhiên, nếu có điều kiện là biến C , nghĩa là C đã được biết giá trị, theo quy tắc xác suất có điều kiện, ta có $P(ABC) = P(AB|C)P(C)$.

Dựa trên đồ thị ta lại có $P(ABC) = P(A)P(C|A)P(B|C)$. Kết hợp cả hai, suy ra được:

$$P(AB|C) = P(A|C)P(B|C) \quad (5)$$

Vì vậy, $A \perp B | C$. Vậy với cấu trúc nối tiếp C phụ thuộc A và B phụ thuộc C , ta nói rằng: A và B phụ thuộc nếu không có thông tin về C , nhưng A và B độc lập khi đã có thông tin về C .

b/ Cấu trúc phân kỳ:

Phân tích một cách tương tự, ta có $A \perp B | \phi$ và $A \perp B | C$. Nghĩa là nếu không có thông tin về C , ta sẽ có A và B độc lập và ngược lại, nếu có thông tin về C , A và B sẽ không còn độc lập.

c/ Cấu trúc hội tụ:

Từ phân phối chung, ta suy ra được rằng nếu không biết C thì $P(AB) = P(A)P(B)$, hay $A \perp B | \phi$. Tiếp tục suy luận với thông tin đã biết về C , ta có $A \perp B | C$. Vậy sự độc lập của cấu trúc hội tụ tương tự như sự độc lập của cấu trúc phân kỳ và ngược với sự độc lập có điều kiện của cấu trúc nối tiếp.

3. Xây dựng mô hình áp dụng để dự đoán xác suất

3.1. Giới thiệu bài toán áp dụng

Bài báo chọn bài toán dự đoán xác suất các sự kiện liên quan đến hoàn cảnh và khả năng bỏ học của sinh viên Trường Đại học Duy Tân để trình

bày cách thức vận dụng mạng Bayes cũng như làm nổi bật các ưu điểm của mạng Bayes. Để thực hiện áp dụng, bài báo sử dụng dữ liệu chứa 1000 bản ghi đại diện cho cả dữ liệu học tập và xã hội của các sinh viên khóa học (chỉ thu thập dữ liệu thống kê, không thu thập danh tính). Sau đó, các mô hình xác suất này được giải thích và đánh giá.

Dữ liệu thu thập có 9 trường bao gồm “điểm đầu vào” (DDV), tình trạng “sức khỏe” (SK), mức độ “vắng học”, trạng thái “có việc làm”

thêm khi đang học hay không (CVL), “kinh tế gia đình” (KTGD), số lượt tham gia “cố vấn học tập” (CVHT), “khoảng cách từ nhà đến trường” (KCNT), học lực thông qua “điểm trung bình” (DTB), và cuối cùng là khả năng “bỏ học” của sinh viên đó (BoHoc). Ở các trường có miền giá trị liên tục, chúng tôi phân thành các khoảng giá trị để tiện việc đánh giá và tính toán xác suất. Ở các trường không có giá trị là số mà là giá trị chuỗi kí tự cũng được thay thế bằng các số nguyên. Chi tiết của từng trường được trình bày trong Bảng 1.

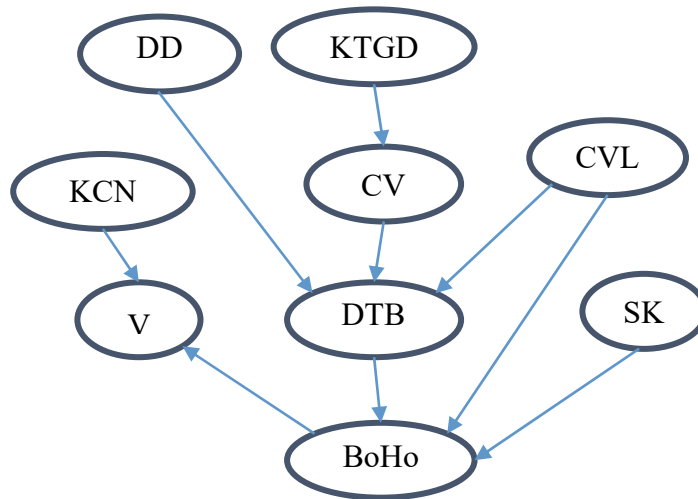
Bảng 1. Mô tả các đặc tính và sự chuyển đổi thành các giá trị của các biến ngẫu nhiên

STT	Tên biến	Mô tả	Giá trị
1	DDV	“điểm đầu vào”	$14 \rightarrow 18 = 1$; $19 \rightarrow 24 = 2$; $24 \rightarrow 30 = 3$
2	SK	“sức khỏe”	Tốt = 1; Trung bình = 2; Không tốt = 3
3	HV	mức độ “vắng học”	Nhiều = 1; Ít = 2
4	CVL	“có việc làm” thêm khi đang học	Yes = 1; No = 2
5	KTGD	“kinh tế gia đình”	Khá = 1; Trung bình = 2; Nghèo = 3
6	CVHT	số lượt tham gia “cố vấn học tập”	$0 \rightarrow 0$; $1 \rightarrow 5 = 1$; 6 trở lên = 2
7	KCNT	“khoảng cách từ nhà đến trường”	$1 \rightarrow 50 = 1$; $51 \rightarrow 200 = 2$; 200 trở lên = 3
8	DTB	“điểm trung bình”	$1.00 \rightarrow 2.65 = 1$; $2.66 \rightarrow 3.65 = 2$; $3.66 \rightarrow 4.00 = 3$
9	BoHoc	“bỏ học”	True=1; False=0

3.2. Thực nghiệm và kết quả

Sau khi dữ liệu được chuyển đổi giá trị và chuẩn hóa sang số thực, đồ thị xác suất mạng Bayes được xây dựng dựa vào sự phụ thuộc đơn giữa các trường dữ liệu như trong Hình 2. Ma trận tương quan được tính toán nhằm rút ra các cặp trường dữ liệu có độ tương quan lớn. Các cặp này được xác định bởi các giá trị có trị tuyệt đối lớn hơn 0.5 và không nằm trên đường chéo

của ma trận tương quan. Ngưỡng 0.5 được chọn vì giá trị tương quan có trị tuyệt đối nằm trong đoạn $[0,1]$, và giá trị lớn hơn 0.5 được coi là tương quan mạnh, giá trị dưới 0.5 được coi là tương quan yếu hoặc chỉ là nhiễu dữ liệu nếu có giá trị gần 0. Tiếp theo, chiều phụ thuộc giữa các cặp được xác định dựa vào ý kiến tham khảo từ các cố vấn học tập và mạng Bayes khi đó có cấu trúc như sau:



Hình 2. Mạng Bayes cho bài toán ước lượng xác suất liên quan đến hoàn cảnh và khả năng bỏ học của sinh viên.

Sau đó mạng Bayes được huấn luyện để thu nhận các thông tin xác suất nhằm đưa ra các tính toán cho một xác suất có điều kiện bất kì. Giao diện chương trình ngoài hình vẽ mạng Bayes là nơi nhập thông tin cho 9 trường dữ liệu, và trường dữ liệu cần tính xác suất (xem Hình 2). Mạng Bayes được huấn luyện trên Google Colab, ngôn ngữ Python 3.0, thư viện PGM. Giao diện web được dựng bằng ngôn ngữ Python 3.65, viết trên IDE Pycharm, dựa trên Framework Flask 2.0.1. Phần nội dung hiển thị giao diện được tham khảo từ [8], trong đó đồ thị được tách thành 2 phần: phần đồ thị và phần

nhập dữ liệu, và check box ở phần dữ liệu được thay bằng drop box.

Trong trường hợp không có thông tin của biến sự kiện nào được nhập, ngõ ra sẽ là tiên xác suất (prior), là xác suất không có điều kiện. Ví dụ như trong Hình 2, tiên xác suất bỏ học của một sinh viên là 0.12. Nhưng nếu muốn biết $P(\text{BoHoc}=1|\text{KTGD}=3)$, nghĩa là nếu gia cảnh nghèo thì khả năng bỏ học là bao nhiêu, thì ta chọn mức Nghèo ở trường “kinh tế gia đình”, chọn ngõ ra là “bỏ học” thì kết quả xác suất bỏ học của một sinh viên sẽ là 0.23.

Các biến sự kiện

Kinh tế gia đình <input type="text" value="-- Không chọn --"/>	Điểm đầu vào <input type="text" value="-- Không chọn --"/>	Có việc làm <input type="text" value="-- Không chọn --"/>
Sức khỏe <input type="text" value="-- Không chọn --"/>	Khoảng cách nhà-trường <input type="text" value="-- Không chọn --"/>	Vắng học <input type="text" value="-- Không chọn --"/>
Thường gặp cố vấn học tập <input type="text" value="-- Không chọn --"/>	Điểm trung bình <input type="text" value="-- Không chọn --"/>	Bỏ học <input type="text" value="-- Không chọn --"/>

Biến sự kiện cần ước lượng xác suất

Bỏ học
-- Select --

Kết quả: P(True): 0.12
 P(False): 0.88

Hình 3. Giao diện chương trình ước lượng xác suất.

Kiểm chứng về sự độc lập giữa các biến sự kiện trong một PGM cho thấy mạng Bayes sau khi được huấn luyện thực hiện đúng với lý thuyết về sự độc lập có điều kiện. Ví dụ: “điểm đầu vào” và “có việc làm” sẽ độc lập khi chưa có thông tin về “điểm trung bình”, nghĩa là nếu chọn các giá trị khác nhau cho “điểm đầu vào” và xem kết quả xác suất “có việc làm” ở ngõ ra thì ta thấy xác suất ngõ ra không thay đổi. Nhưng nếu chọn một giá trị nào đó cho “điểm trung bình”, khi đó với những giá trị khác nhau của “điểm đầu vào” thì xác suất “có việc làm” có những giá trị khác nhau. Việc kiểm chứng này không chỉ đúng với cấu trúc hội tụ mà còn đúng với cấu trúc nối tiếp (bài toán này không có cấu trúc phân kì thuận). Ví dụ: “thường gặp cố vấn học tập” sẽ độc lập với “bỏ học” nếu đã biết được “điểm trung bình” và ngược lại. Ngoài ra, sự độc lập này cũng không nhất thiết là cấu trúc nối tiếp gần, mà còn đúng cho cấu trúc nối tiếp xa. Ví dụ như “điểm đầu vào” sẽ độc lập với “vắng học” nếu đã biết “điểm trung bình”, mặc dù trên liên kết nối tiếp có cả nút “bỏ học”.

Bên cạnh đó, việc sử dụng mạng Bayes cho thêm một số kết luận sau:

- Một sinh viên trong điều kiện bình thường thì khả năng bỏ học rất thấp. Ví dụ như khi chọn thông số “điểm trung bình”: cao, “sức khỏe”: tốt, “có việc làm”: chưa, thì kết quả của trường “bỏ học” là 0.96 cho việc không bỏ học và 0.04 cho việc bỏ học.

- Mô hình được cung cấp thông tin là: “điểm trung bình”: thấp, “sức khỏe”: không tốt, “có việc làm”: đã có việc làm. Kết quả của trường “bỏ học” là 37% cho việc không bỏ học và 63% cho việc bỏ học. Trường hợp này mô hình dự đoán là khả năng bỏ học là cao.

- Nếu trường “bỏ học” là true (có nghĩa là bỏ học) thì nguyên nhân do kinh tế gia đình là không đáng kể (xác suất gia cảnh tốt, trung bình, nghèo là gần bằng nhau). Nếu trường “bỏ học” là true (có nghĩa là bỏ học) thì nguyên nhân do

công việc là không đáng kể. Nếu trường “bỏ học” là true (có nghĩa là bỏ học) thì nguyên nhân chủ yếu là do “điểm trung bình” thấp (68%).

Rõ ràng, mô hình mạng Bayes rất hiệu quả đối với việc phân tích các mối quan hệ giữa các yếu tố tác động lẫn nhau và tác động lên một biến ngẫu nhiên được quan tâm đặc biệt nào đó (ở bài toán thực tế trong bài báo này là biến “bỏ học”). Mô hình giúp phân tích được với một yếu tố đã xảy ra (hoặc một tập các điều kiện đã xảy ra) thì nguyên nhân dẫn đến chủ yếu là gì, tác động của trạng thái cụ thể đó ảnh hưởng như thế nào đến những yếu tố hệ quả, cũng như tìm thấy sự độc lập xác suất của các yếu tố khác liên quan.

Chú ý rằng, mạng Bayes sau khi được huấn luyện thì không cần lưu trữ dữ liệu. Nghĩa là giống như đa số các phương pháp Học máy tiên tiến, mạng Bayes có khả năng chuyển dữ liệu thành tri thức để có thể tính toán ra quyết định về sau. Mạng Bayes vận hành tốt với các đầu vào bị thiếu hụt thông tin, hoặc khi hoàn toàn không có thông tin thì mạng vẫn đưa ra các kết quả xác suất (tiền xác suất). Ngoài ra, mạng Bayes không chỉ dùng để đánh giá xác suất của trường kết quả phụ thuộc mà còn có thể đánh giá xem xác suất của các nguyên nhân. Do vậy đây là một phương pháp có thể áp dụng vào những bài toán có các yêu cầu tương tự như bài toán được trình bày trong bài báo.

4. Kết luận

Bài báo đã giới thiệu phương pháp Học máy mạng Bayes dành cho việc ước lượng các xác suất có điều kiện phức hợp, trong đó tri thức sau quá trình huấn luyện là thông tin của các đường liên kết trong mô hình điều kiện xác suất (PGM). Mạng không chỉ cho phép suy luận tới theo chiều ảnh hưởng của biến ngẫu nhiên mà cho phép suy luận lui để tìm và đánh giá nguyên nhân tác động lên một biến ngẫu nhiên cụ thể nào đó. Bài báo đã áp dụng phương pháp này giải quyết một bài toán cụ thể cho phép ước lượng các xác suất liên hệ giữa các trường hoàn cảnh và khả năng bỏ học

của sinh viên, cho thấy được các điểm mạnh mà phương pháp này mang lại, giúp hiểu rõ hơn cũng như vận dụng vào các bài toán thực tế tương tự khác.

Tài liệu tham khảo

- [1] Marco Scutari, Jean-Baptiste Denis. (2021). *Bayesian Networks*. Place of publication: Chapman and Hall/CRC.
- [2] Cheng, J. and Greiner, R.. (1999). Comparing Bayesian Network classifiers. *Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence (UAI1999), Stockholm Sweden, 1999*. Place of publication: Morgan Kaufmann.
- [3] Wiegerinck, W., Burgers, W., Kappen, B.. (2013). "Bayesian Networks, Introduction and Practical Applications". *Handbook on Neural Information Processing* (49), 401–431.
- [4] Chuyue Lou, Xiangshun Li*, and M. Amine Atoui. (2020). "Bayesian Network Based on an Adaptive Threshold Scheme for Fault Detection and Classification". *Industrial & Engineering Chemistry Research* (59), 15155–15164.
- [5] Marcot, B. G.. (2012). "Metrics for evaluating performance and uncertainty of Bayesian Network Models". *Ecological Modelling*, (230), 50-62.
- [6] Kibret T, Richer D, Beyene J.. (2014). "Bias in identification of the best treatment in a Bayesian network meta-analysis for binary outcome: a simulation study". *Clin Epidemiol* (6), 451-460.
- [7] Uffe B. Kjærulff, Anders L. Madsen. (2010). *Bayesian Networks and Influence Diagrams: A Guide to Construction and Analysis*. Place of publication: Springer New York.
- [8] Bayes Server. (2020). *Asia Example*. Access time: 15/03/2024, from <https://www.bayesserver.com/examples/networks/asia>.