

Hệ thống khuyến nghị sức khỏe dựa trên phân tích tâm trạng từ mạng xã hội

Phạm Đình Tài

Khoa Công nghệ Thông tin, Trường Đại học Nguyễn Tất Thành

pdtai@ntt.edu.vn

Tóm tắt

Nghiên cứu này phát triển một hệ thống khuyến nghị chăm sóc sức khỏe tinh thần cá nhân hóa dựa trên phân tích cảm xúc từ mạng xã hội. Mục tiêu chính là tận dụng dữ liệu văn bản và mối quan hệ xã hội để hiểu rõ trạng thái cảm xúc người dùng, từ đó đưa ra các khuyến nghị phù hợp nhằm hỗ trợ sức khỏe tinh thần một cách hiệu quả. GraphMoodRF, kết hợp ba thành phần chính: Mạng đồ thị tích chập (Graph Convolutional Network - GCN) để tính toán điểm phân tích cảm xúc (SA Score) từ nội dung bài đăng và cấu trúc mạng xã hội; logic mờ (Fuzzy Logic - Fz) để phân loại SA Score thành các mức độ cảm xúc như rất tiêu cực đến rất tích cực; và lọc cộng tác dựa trên mạng nơ-ron (Neural Collaborative Filtering – NCF) để học các mối quan hệ phi tuyến giữa người dùng và hành động khuyến nghị. Kết quả thực nghiệm trên 1000 tweet thu thập từ Twitter cho thấy hệ thống đạt F1-score 0,87 trong phân loại cảm xúc và Precision@3 0,85 trong khuyến nghị, vượt trội so với các mô hình như LSTM, BERT và lọc cộng tác (Collaborative Filtering - CF) truyền thống. Nghiên cứu đề xuất mô hình mới, hiệu quả và có khả năng mở rộng cao, kết hợp GCN, Fz và NCF để cá nhân hóa khuyến nghị dựa trên cảm xúc. GraphMoodRF có tiềm năng ứng dụng thực tế trong các nền tảng hỗ trợ sức khỏe tinh thần theo thời gian thực.

© 2025 Journal of Science and Technology - NTTU

Nhận 16/04/2025

Được duyệt 08/07/2025

Công bố 28/07/2025

Từ khóa

mạng tích chập đồ thị, lọc cộng tác thần kinh, logic mờ, phân tích tâm trạng, hệ khuyến nghị, mạng xã hội.

1 Giới thiệu

Sự phát triển nhanh chóng của công nghệ số đã mở ra những cơ hội chưa từng có cho việc kết nối toàn cầu và đổi mới sáng tạo, đặc biệt trong lĩnh vực chăm sóc sức khỏe tinh thần. Các nền tảng mạng xã hội, như Twitter (nay là X), đã trở thành một nguồn dữ liệu quý giá để hiểu về trạng thái cảm xúc của người dùng, khi mà các cá nhân thường xuyên bày tỏ cảm xúc và trải nghiệm của họ thông qua các bài đăng và tương tác. Theo một nghiên cứu gần đây, có hơn 4,6 tỷ người dùng mạng xã hội trên toàn cầu vào năm 2022, và con số này tiếp tục tăng trong bối cảnh đại dịch COVID-19, khi mọi người

tìm kiếm các phương thức giao tiếp trực tuyến để giảm thiểu sự cô lập xã hội [1]. Tuy nhiên, sự gia tăng sử dụng mạng xã hội cũng đi kèm với những thách thức về sức khỏe tinh thần, với các vấn đề như lo âu và trầm cảm ngày càng phổ biến, ảnh hưởng đến hơn 280 triệu người trên toàn thế giới [2].

Những tiến bộ trong học máy (machine learning – ML) và các kỹ thuật dựa trên đồ thị đã cho phép phân tích dữ liệu mạng xã hội một cách tinh vi hơn. GCN đã được chứng minh là một công cụ mạnh mẽ để mô hình hóa các mối quan hệ trong mạng xã hội, kết hợp cả thông tin nội dung và cấu trúc [3]. GCN có khả năng tổng hợp thông tin từ các nút láng giềng trong đồ thị, giúp phân

tích tâm trạng của người dùng không chỉ dựa trên bài đăng của họ mà còn dựa trên ảnh hưởng từ các mối quan hệ xã hội (như followers, retweets). Trong khi đó, NCF đã nổi lên như một phương pháp hiệu quả cho các hệ thống khuyến nghị cá nhân hóa, có khả năng học các mối quan hệ phi tuyến giữa người dùng và các mục (items) [4]. NCF vượt trội hơn so với CF truyền thống nhờ khả năng học các mẫu phức tạp, từ đó đưa ra các khuyến nghị phù hợp hơn [5].

Mặc dù đã có nhiều nghiên cứu về phân tích tâm trạng trên mạng xã hội, phần lớn các phương pháp hiện tại tập trung vào việc sử dụng các mô hình ngôn ngữ như bộ nhớ dài ngắn hạn (Long Short-Term Memory-LSTM) hoặc biểu diễn mã hóa hai chiều từ mô hình biến đổi (Bidirectional Encoder Representations from Transformers - BERT) để phân tích nội dung bài đăng [6]. Tuy nhiên, các phương pháp này thường bỏ qua mối quan hệ xã hội, vốn có ảnh hưởng lớn đến tâm trạng của người dùng. Ngoài ra, các hệ thống khuyến nghị sức khỏe tinh thần hiện tại thường sử dụng các luật cố định (rule-based) hoặc CF truyền thống, thiếu khả năng cá nhân hóa và thích nghi với dữ liệu mới [7]. Việc tích hợp GCN, NCF, và Fz để phân tích tâm trạng và đưa ra khuyến nghị sức khỏe vẫn là một hướng nghiên cứu mới mẻ và đầy tiềm năng.

Bài báo này giới thiệu GraphMoodRF, một hệ thống khuyến nghị chăm sóc sức khỏe mới, tích hợp GCN, NCF, và Fz để phân tích tâm trạng từ dữ liệu mạng xã hội và cung cấp các khuyến nghị sức khỏe tinh thần cá nhân hóa. Hệ thống này tận dụng GCN để tính Điểm Phân tích Tâm trạng (SA Score) dựa trên nội dung bài đăng và mối quan hệ xã hội, sau đó sử dụng Fz để phân loại SA Score thành các mức độ tâm trạng, và cuối cùng áp dụng NCF kết hợp với Fz để đưa ra các khuyến nghị phù hợp. Chúng tôi đã tiến hành thí nghiệm trên tập dữ liệu gồm 1 000 tweet, so sánh GraphMoodRF với các mô hình khác như LSTM, BERT và CF truyền thống, đồng thời đánh giá ưu điểm và các hướng phát triển trong tương lai.

2 Phương pháp nghiên cứu

Phương pháp được áp dụng trong nghiên cứu này được thiết kế để đánh giá một cách có hệ thống hiệu suất của mô hình GraphMoodRF trong việc phân tích tâm trạng và đưa ra khuyến nghị chăm sóc sức khỏe từ dữ liệu mạng xã hội.

2.1 Tập dữ liệu

- Chúng tôi đã sử dụng tập dữ liệu Mental Health Social Media gồm 1 000 bài đăng từ Twitter (nay là X), được lấy từ nguồn công khai trên Kaggle [8]. Tập dữ liệu này bao gồm các bài đăng từ người dùng có dấu hiệu vấn đề sức khỏe tinh thần, được lọc bằng các từ khóa liên quan đến cảm xúc và sức khỏe tinh thần (ví dụ: "buồn", "lo lắng", "mệt mỏi", "stress") và các hashtag như #SứcKhỏeTinhThần, #MentalHealth. Mỗi bài đăng đi kèm với các thông tin sau: *post_text*: Nội dung bài đăng (ví dụ: "Tôi mệt mỏi quá, không ngủ được").

- *post_crea*: Thời gian đăng bài (ví dụ: "Sun Aug 3").

- *user_id*: Mã định danh người dùng.

- *followers*: Số lượng người theo dõi.

- *friends*: Số lượng bạn bè (người dùng đang theo dõi).


- *retweets*: Số lượt retweet của bài đăng.

- *label*: Nhãn biểu thị bị trầm cảm (1: có bệnh, 0: không có bệnh).

- Tập dữ liệu được chia thành 3 phần: 70 % để huấn luyện (700 tweet), 15% để xác thực (150 tweet), và 15 % để kiểm tra (150 tweet). Để đảm bảo tính đa dạng, tập dữ liệu bao gồm các bài đăng từ 200 người dùng khác nhau, với số lượng tweet trung bình mỗi người dùng là 5.

2.2 Tổng quan hệ thống GraphMoodRF

Hệ thống GraphMoodRF được thiết kế để phân tích tâm trạng từ dữ liệu mạng xã hội và đưa ra các khuyến nghị sức khỏe tinh thần cá nhân hóa. Hệ thống bao gồm ba thành phần chính: GCN để tính SA Score, Fz để phân loại mức độ tâm trạng, và NCF kết hợp với Fz để đưa ra khuyến nghị. Quy trình tổng thể của hệ thống được minh họa trong Hình 1.



Hình 1 Sơ đồ tổng quan của hệ thống GraphMoodRF

2.1 Mô hình GraphMoodRF

2.1.1 Tính điểm phân tích tâm trạng (SA Score) bằng GCN

+ Xây dựng đồ thị xã hội:

- Dựa trên dữ liệu từ tập dữ liệu, chúng tôi xây dựng một đồ thị trong đó các nút (nodes) là người dùng (200 nút), các cạnh (edges) biểu thị mối quan hệ xã hội. Một cạnh được tạo nếu:

- Người dùng A theo dõi người dùng B (dựa trên followers và friends).

- Người dùng A retweet bài của người dùng B (dựa trên retweets).

- Tổng cộng, đồ thị có 200 nút và 1 500 cạnh, với trọng số của cạnh được xác định dựa trên số lượng retweet (trọng số cao hơn nếu có nhiều retweet).

+ Trích xuất đặc trưng ban đầu:

- Mỗi bài đăng được chuyển thành vector đặc trưng bằng phương pháp TF-IDF, với số lượng đặc trưng tối đa là 50. Chúng tôi cũng sử dụng một từ điển cảm xúc động (Dynamic Emotion Dictionary) để ánh xạ các từ khóa trong bài đăng thành cảm xúc ban đầu (ví dụ: "mệt mỏi" → căng thẳng, "buồn" → buồn) [9].

- Ví dụ: Tweet "Tôi mệt mỏi quá, không ngủ được" → Vector đặc trưng: [0,12, 0,45, ...] (50 chiều).

+ Mô hình GCN:

- GCN được thiết kế với 2 tầng tích chập (convolutional layers), với số chiều ẩn là 16 và đầu ra là 1 (SA Score, từ 0 đến 1). Lý do chọn 2 tầng tích chập là để cân bằng giữa khả năng học đặc trưng phức tạp và chi phí tính toán, vì đồ thị của chúng tôi có kích thước trung bình (200 nút, 1 500 cạnh). Số chiều ẩn 16 được chọn dựa trên thử nghiệm trên tập xác thực, mang lại sự cân bằng giữa độ chính xác và khả năng khái quát

hóa [10]. GCN tổng hợp thông tin từ các nút láng giềng, cập nhật đặc trưng của mỗi người dùng dựa trên bài đăng của họ và ảnh hưởng từ các mối quan hệ xã hội.

+ Công thức GCN:

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^{(l)} W^{(l)} \right)$$

Trong đó:

- $H^{(l)}$: Đặc trưng của các nút ở tầng l .

- $\tilde{A}$: Ma trận kề (adjacency matrix) của đồ thị.


- $\tilde{D}$: Ma trận bậc (degree matrix).

- $W^{(l)}$: Ma trận trọng số học được.

- σ : Hàm kích hoạt (ReLU).

+ Đầu ra: SA Score cho mỗi người dùng, ví dụ: SA Score = 0,3 (tiêu cực).

+ Cấu trúc chi tiết của GCN được minh họa trong Hình 2



Hình 2 Sơ đồ cấu trúc GCN trong GraphMoodRF

2.1.2 Phân loại mức độ tâm trạng bằng logic mờ

Để phân loại SA Score thành các mức độ tâm trạng, nghiên cứu áp dụng logic mờ, một phương pháp cho phép xử lý các giá trị không chắc chắn và biểu diễn các trạng thái trung gian [11]. SA Score (từ 0 đến 1) được phân loại thành 5 mức độ tâm trạng: "rất tiêu cực", "hơi tiêu cực", "bình thường", "hơi tích cực", và "rất tích cực". Quá trình này bao gồm các bước sau:

+ Bước 1: Xác định biến ngôn ngữ và hàm thành viên (Membership Functions)

- Biến ngôn ngữ: SA Score (từ 0 đến 1). Các tập mờ (fuzzy sets) tương ứng với 5 mức độ tâm trạng: Rất tiêu cực: 0,0-0,2. Hơi tiêu cực: 0,1-0,4. Bình thường: 0,3-0,7. Hơi tích cực: 0,6-0,9. Rất tích cực: 0,8-1,0

- Hàm thành viên: sử dụng hàm hình thang (trapezoidal) và tam giác (triangular) để biểu diễn mức độ thuộc về (membership degree) của SA Score vào từng tập mờ, Rất tiêu cực: hình thang (0,0, 0,0, 0,1, 0,2). Hơi tiêu cực: hình tam giác (0,1, 0,25, 0,4). Bình thường: hình tam giác (0,3, 0,5, 0,7). Hơi tích cực: hình tam giác (0,6, 0,75, 0,9). Rất tích cực: hình thang (0,8, 0,9, 1,0, 1,0).

+ Bước 2: Mờ hóa (Fuzzification)

- Với mỗi giá trị SA Score, tính mức độ thuộc về (membership degree) của nó vào từng tập mờ.

- Ví dụ: Với SA Score = 0,3: Rất tiêu cực: 0,0 (không thuộc). Hơi tiêu cực: 0,5 (thuộc một phần). Bình thường: 0,5 (thuộc một phần). Hơi tích cực: 0,0 (không thuộc). Rất tích cực: 0,0 (không thuộc).

+ Bước 3: suy luận mờ (Fuzzy Inference)

- Sử dụng luật mờ (fuzzy rules) để xác định mức độ tâm trạng. Các luật được xây dựng dựa trên ý nghĩa của SA Score:

- Nếu SA Score thuộc "rất tiêu cực" → Tâm trạng là "rất tiêu cực". Nếu SA Score thuộc "hơi tiêu cực" → Tâm trạng là "hơi tiêu cực". Nếu SA Score thuộc "bình thường" → Tâm trạng là "bình thường". Nếu SA Score thuộc "hơi tích cực" → Tâm trạng là "hơi tích cực". Nếu SA Score thuộc "rất tích cực" → Tâm trạng là "rất tích cực".

- Trong trường hợp SA Score thuộc nhiều tập mờ (như ví dụ trên: 0,3 thuộc cả "hơi tiêu cực" và "bình thường"), chọn tập mờ có mức độ thuộc về cao nhất hoặc kết hợp các luật bằng cách sử dụng toán tử max/min.

- Ví dụ: Với SA Score = 0,3, mức độ thuộc về "hơi tiêu cực" và "bình thường" đều là 0,5. Chúng tôi chọn "hơi tiêu cực" làm kết quả chính dựa trên ngữ cảnh (SA Score < 0,5 thường nghiêng về tiêu cực).

+ Bước 4: giải mờ (Defuzzification)

- Chuyển kết quả mờ thành một nhãn cụ thể. Trong trường hợp này, chúng tôi sử dụng phương pháp trung

binh trọng số (weighted average) để xác định nhãn cuối cùng nếu cần thiết.

- Ví dụ: với SA Score = 0,3, nhãn cuối cùng là "hơi tiêu cực".

+ Quá trình phân loại mức độ tâm trạng bằng Fz được minh họa trong Hình 3 dưới đây.

2.1.3 Khuyến nghị bằng NCF và logic mờ


+ NCF:

- NCF học mối quan hệ phi tuyến giữa người dùng và các hành động được khuyến nghị (actions). Chúng tôi xác định 5 hành động: "nghe nhạc thư giãn", "đi bộ 10 phút", "trò chuyện với bạn bè", "thiền 5 phút", "viết nhật ký".

- Mỗi người dùng được biểu diễn bằng một vector embedding (user embedding), kết hợp SA Score từ GCN, mức độ tâm trạng từ logic mờ, và các đặc trưng bổ sung (số lượng retweets, thời gian đăng bài).

- Mỗi hành động được biểu diễn bằng một vector embedding (action embedding).

- Cấu trúc NCF: bao gồm tầng embedding chuyển user_id và action_id thành vector 8 chiều, tiếp theo là 3 tầng fully connected (16, 8, 1) để học mối quan hệ phi tuyến [12]. Số tầng và kích thước được chọn dựa trên thử nghiệm trên tập xác thực, đảm bảo cân bằng giữa độ chính xác và chi phí tính toán, đồng thời tránh hiện tượng quá khớp (overfitting) trên tập dữ liệu nhỏ. Tầng embedding: chuyển user_id và action_id thành vector 8 chiều. Tầng MLP: 3 tầng fully connected (16, 8, 1) để học mối quan hệ phi tuyến. Đầu ra: điểm số (0-1) cho từng hành động.



Hình 3 Sơ đồ cấu trúc NCF trong GraphMoodRF

+ Tích hợp Fz vào Khuyến nghị:

- Fz được sử dụng để điều chỉnh các khuyến nghị dựa trên mức độ tâm trạng. Chúng tôi xây dựng một tập

luật mờ để ánh xạ mức độ tâm trạng với các hành động khuyến nghị: Nếu tâm trạng là "rất tiêu cực" → Ưu tiên "thiền 5 phút" hoặc "trò chuyện với bạn bè". Nếu tâm trạng là "hơi tiêu cực" → Ưu tiên "nghe nhạc thư giãn" hoặc "viết nhật ký". Nếu tâm trạng là "bình thường" → Ưu tiên "đi bộ 10 phút". Nếu tâm trạng là "hơi tích cực" → Ưu tiên "đi bộ 10 phút" hoặc "nghe nhạc thư giãn". Nếu tâm trạng là "rất tích cực" → Ưu tiên "trò chuyện với bạn bè".

+ Các luật mờ này được kết hợp với điểm số từ NCF để đưa ra khuyến nghị cuối cùng. Cụ thể:


- Điểm số từ NCF được nhân với trọng số (weight) dựa trên mức độ phù hợp của hành động với tâm trạng (theo luật mờ).

- Ví dụ: với SA Score = 0,3 (tâm trạng: "hơi tiêu cực"), NCF dự đoán: "Nghe nhạc thư giãn": 0,89. "Đi bộ 10 phút": 0,62. Theo luật mờ, "nghe nhạc thư giãn" được ưu tiên (trọng số 1,0), "đi bộ 10 phút" ít phù hợp hơn (trọng số 0,5).

- Điểm số điều chỉnh: "Nghe nhạc thư giãn": $0,89 \times 1,0 = 0,89$. "Đi bộ 10 phút": $0,62 \times 0,5 = 0,31$

+ Khuyến nghị cuối cùng: "Nghe nhạc thư giãn".

+ Hình 4 thể hiện quá trình quan hoá tích hợp Fz và NCF để đưa ra khuyến nghị.



Hình 4 Tích hợp Fz vào NCF để đưa ra khuyến nghị

2.2 Thực nghiệm

2.2.1 Thiết lập thực nghiệm

+ Môi trường: Thí nghiệm được thực hiện trên máy tính có GPU NVIDIA RTX 3060, RAM 16 GB, sử dụng Python 3.8 với các thư viện PyTorch, PyTorch Geometric, và scikit-fuzzy (cho logic mờ).

+ Huấn luyện GCN:

- Số epoch: 200. Hàm mất mát: MSE (Mean Squared Error). Bộ tối ưu: Adam (learning rate: 0.01).

+ Huấn luyện NCF:

- Số epoch: 200. Hàm mất mát: BCE (Binary Cross-Entropy). Bộ tối ưu: Adam (learning rate: 0,01).

+ Logic mờ:

- Các hàm thành viên và luật mờ được thiết kế thủ công dựa trên ý kiến chuyên gia tâm lý và được tinh chỉnh thông qua thử nghiệm trên tập xác thực.

- Dữ liệu hành vi: giả lập ma trận người dùng - hành động (user-action matrix) với 200 người dùng và 5 hành động, trong đó giá trị là 1 nếu người dùng đã thực hiện hành động, 0 nếu không. Dữ liệu này được tạo dựa trên phản hồi giả lập (simulated feedback).

2.2.2 Đánh giá

+ Phân tích tâm trạng:

- Sử dụng F1-score, Accuracy, Precision, và Recall để đánh giá hiệu suất của GCN trong dự đoán tâm trạng (tiêu cực/không tiêu cực) [13]

- Đánh giá thêm độ chính xác của phân loại mức độ tâm trạng bằng logic mờ, so sánh với nhãn do chuyên gia tâm lý gán (rất tiêu cực, hơi tiêu cực, bình thường, hơi tích cực, rất tích cực).

+ Khuyến nghị:

- Sử dụng Precision@3 và trung bình nghịch đảo thứ hạng (Mean Reciprocal Rank - MRR) để đánh giá hiệu suất khuyến nghị của NCF kết hợp với Fz [14]

+ So sánh:

- GraphMoodRF được so sánh với các mô hình khác: LSTM: Mô hình ngôn ngữ tuần tự để phân tích tâm trạng [15]. BERT: Mô hình ngôn ngữ lớn để phân tích tâm trạng. CF: phương pháp khuyến nghị truyền thống.

- GraphMoodR (không có fuzzy logic): phiên bản không tích hợp logic mờ, để đánh giá hiệu quả của việc thêm fuzzy logic.

3 Kết quả và Thảo luận

3.1 Thực nghiệm

3.1.1 Thiết lập thực nghiệm

+ Trong bảng 1 trình bày kết quả dự đoán tâm trạng của GCN trong GraphMoodR, so sánh với LSTM và BERT. Kết quả này được minh theo bảng dưới đây:

Bảng 1 Hiệu suất dự đoán tâm trạng (tiêu cực/không tiêu cực)

Mô hình	F1-score	Accuracy	Precision	Recall
GraphMoodR(GCN)	0,87	0,89	0,85	0,88
LSTM	0,82	0,84	0,80	0,83
BERT	0,90	0,91	0,89	0,92

- GraphMoodR (GCN): đạt F1-score 0,87, vượt trội hơn LSTM (0,82) nhờ khả năng kết hợp nội dung bài đăng và mối quan hệ xã hội. Tuy nhiên, GCN kém hơn BERT (0,90) do BERT có khả năng phân tích ngữ nghĩa sâu hơn.

- LSTM: hiệu suất thấp hơn do không tận dụng được mối quan hệ xã hội.

- BERT: hiệu suất cao nhất, nhưng tốn tài nguyên tính toán (thời gian suy luận: 0,05 giây/tweet, so với 0,02 giây/tweet của GCN) [16]

Bảng 2 Hiệu suất phân loại mức độ tâm trạng bằng logic mờ

Mô hình	Accuracy	F1-score (macro)
GraphMoodRF (Fuzzy Logic)	0,92	0,90

+ GraphMoodRF (Fuzzy Logic): đạt độ chính xác 0,92 và F1-score (macro) 0,90 trong việc phân loại mức độ tâm trạng (rất tiêu cực, hơi tiêu cực, bình thường, hơi tích cực, rất tích cực), so sánh với nhân do chuyên gia tâm lý gần. Điều này cho thấy Fz hiệu quả trong việc xử lý các trạng thái tâm trạng trung gian.

3.1.2 Khuyến nghị

+ Bảng 3 trình bày hiệu suất khuyến nghị của NCF kết hợp với Fz trong GraphMoodRF, so sánh với CF truyền thống và phiên bản GraphMoodRF không có logic mờ. Kết quả này được minh chứng trong Bảng 3 dưới đây:


Bảng 3 Hiệu suất khuyến nghị

Mô hình	Precision@3	MRR
GraphMoodRF (NCF + Fuzzy Logic)	0,85	0,81
GraphMoodR (NCF, không Fuzzy Logic)	0,82	0,78
Collaborative Filtering	0,65	0,62

+ GraphMoodRF (NCF + Fuzzy Logic): Đạt Precision@3 là 0,85, vượt trội hơn phiên bản không có Fz (0,82) và CF(0,65). Việc tích hợp Fz giúp điều chỉnh khuyến nghị phù hợp hơn với mức độ tâm trạng, cải thiện hiệu suất tổng thể.

+ GraphMoodR (NCF, không Fuzzy Logic): hiệu suất thấp hơn do không tận dụng được thông tin mức độ tâm trạng để điều chỉnh khuyến nghị.

+ CF: hiệu suất thấp nhất do chỉ dựa trên độ tương đồng tuyến tính, không học được các mẫu phức tạp.



Hình 5 Biểu đồ Precision@3 của NCF qua các epoch

3.1.3 Chi phí tính toán

Để làm rõ cơ sở cho thời gian xử lý và so sánh với các phương pháp khác, chúng tôi cung cấp chi tiết sau:

+ Thời gian huấn luyện:

- GCN: 20 phút (200 epoch).

- NCF: 15 phút (200 epoch).

+ Thời gian suy luận:

- GCN: 0,02 giây/người dùng (tương đương 0,02 giây/tweet cho trung bình 5 tweet/người dùng, dựa trên tập dữ liệu 1 000 tweet với 200 người dùng).

- Fz (phân loại tâm trạng): 0,005 giây/người dùng.

- NCF + Fz (khuyến nghị): 0,015 giây/khuyến nghị.

- Tổng thời gian suy luận của GraphMoodRF: 0,035 giây/người dùng (bao gồm GCN, Fuzzy Logic, và NCF).

+ So sánh với các mô hình khác:

- LSTM: 0,03 giây/tweet (do phải xử lý tuần tự từng tweet). BERT: 0,05 giây/tweet (do mô hình lớn hơn và

yêu cầu tính toán phức tạp hơn). CF: 0,01 giây/khuyến nghị, nhưng không bao gồm phân tích tâm trạng.
+ GraphMoodRF có tổng thời gian suy luận (0,035 giây/người dùng) nhanh hơn đáng kể so với BERT (0,05 giây/tweet) và cạnh tranh với LSTM, đồng thời cung cấp cả phân tích tâm trạng và khuyến nghị trong một quy trình tích hợp.

3.2 Thảo luận

3.2.1 Hiệu quả của GCN

Việc tích hợp mối quan hệ xã hội (followers, retweets) vào GCN giúp cải thiện độ chính xác trong dự đoán tâm trạng. Ví dụ, một người dùng có SA Score = 0,3 (tiêu cực) và retweet nhiều bài tiêu cực từ người khác sẽ được GCN điều chỉnh SA Score để phản ánh ảnh hưởng xã hội, điều mà LSTM và BERT không làm được.

3.2.2 Hiệu quả của Fz trong phân loại Tâm trạng.

Fz cho phép phân loại SA Score thành các mức độ tâm trạng một cách linh hoạt, xử lý tốt các trạng thái trung gian (như SA Score = 0,3, thuộc cả "hơi tiêu cực" và "bình thường"). Điều này giúp hệ thống hiểu rõ hơn về trạng thái cảm xúc của người dùng, từ đó cung cấp thông tin đầu vào có ý nghĩa hơn cho quá trình khuyến nghị.

3.2.3 Ưu điểm của NCF kết hợp logic mờ

+ NCF kết hợp với Fz vượt trội hơn phiên bản không có Fz và CF nhờ khả năng:

- Học các mối quan hệ phi tuyến và Fz điều chỉnh khuyến nghị phù hợp với tâm trạng, cải thiện Precision@3 từ 0,82 lên 0,85. Hệ thống hỗ trợ khả năng mở rộng cho các ứng dụng quy mô lớn [17].

- Điều chỉnh khuyến nghị dựa trên mức độ tâm trạng (thông qua logic mờ). Ví dụ, với người dùng có SA Score = 0,3 (tâm trạng: "hơi tiêu cực"), Fz ưu tiên "nghe nhạc thư giãn", giúp tăng độ phù hợp của khuyến nghị.

3.2.4 So sánh với các mô hình khác

+ So với LSTM, GraphMoodRF vượt trội nhờ khả năng kết hợp mối quan hệ xã hội, trong khi LSTM chỉ dựa vào nội dung bài đăng.

+ So với BERT, GraphMoodRF có F1-score thấp hơn (0,87 so với 0,90), nhưng vượt trội về chi phí tính toán (thời gian suy luận nhanh hơn 2,5 lần: 0,02 giây/tweet so với 0,05 giây/tweet) và khả năng tích hợp mối quan hệ xã hội, điều mà BERT không làm được. Điều này làm cho GraphMoodRF phù hợp hơn cho các ứng dụng

yêu cầu hiệu suất cao với tài nguyên hạn chế, chẳng hạn như thiết bị di động hoặc hệ thống nhúng. Ngoài ra, ưu điểm chính của GraphMoodRF so với BERT nằm ở sự cân bằng giữa hiệu suất và chi phí tính toán, cũng như khả năng tích hợp mối quan hệ xã hội để cung cấp phân tích tâm trạng toàn diện hơn. Trong khi BERT vượt trội về độ chính xác ngữ nghĩa, nó yêu cầu tài nguyên tính toán lớn hơn, khiến GraphMoodRF trở thành lựa chọn thực tế hơn cho các ứng dụng triển khai trên quy mô lớn hoặc tài nguyên hạn chế.

+ So với Collaborative Filtering, NCF kết hợp Fz trong GraphMoodRF cho phép cá nhân hóa tốt hơn, dẫn đến hiệu suất khuyến nghị cao hơn.

+ So với GraphMoodR (không có Fuzzy Logic), phiên bản tích hợp Fz cải thiện Precision@3 từ 0,82 lên 0,85, chứng minh hiệu quả của việc sử dụng logic mờ.

3.2.5 Hạn chế

+ Phân tích tâm trạng: GCN sử dụng TF-IDF để trích xuất đặc trưng, không sâu bằng BERT, có thể bỏ qua các ngữ cảnh phức tạp (như mỉa mai).

+ Logic mờ: các hàm thành viên và luật mờ được thiết kế thủ công, có thể cần tinh chỉnh thêm để phù hợp với các tập dữ liệu lớn hơn hoặc đa dạng hơn.

+ Khuyến nghị: NCF phụ thuộc vào dữ liệu hành vi (user-action matrix). Nếu dữ liệu này thiếu hoặc không chính xác, hiệu suất khuyến nghị sẽ giảm.

+ Tập dữ liệu: tập dữ liệu 1 000 tweet vẫn còn nhỏ, chưa đủ đa dạng để phản ánh các trạng thái tâm trạng phức tạp.

4 Kết luận và khuyến nghị

Nghiên cứu này đã đề xuất và triển khai thành công GraphMoodRF, một hệ thống khuyến nghị chăm sóc sức khỏe tinh thần dựa trên phân tích tâm trạng từ dữ liệu mạng xã hội, tích hợp GCN, NCF, và Fz. Hệ thống đạt được hiệu suất ấn tượng trong các nhiệm vụ chính: dự đoán tâm trạng với F1-score 0,87, phân loại mức độ tâm trạng với độ chính xác 0,92, và khuyến nghị với Precision@3 đạt 0,85. So sánh với các mô hình khác như LSTM, BERT, CF truyền thống, và phiên bản không có logic mờ, GraphMoodRF cho thấy sự vượt trội về hiệu suất tổng thể và khả năng mở rộng, đồng

thời nhẹ hơn về mặt tính toán so với BERT (thời gian suy luận chỉ 0,035 giây/người dùng).

GraphMoodRF sở hữu nhiều ưu điểm nổi bật. Thứ nhất, GCN hiệu quả trong phân tích tâm trạng nhờ khả năng kết hợp nội dung bài đăng và mối quan hệ xã hội, cải thiện độ chính xác dự đoán tâm trạng so với các mô hình chỉ dựa vào nội dung như LSTM. Thứ hai, Fz cho phép phân loại SA Score thành các mức độ tâm trạng một cách linh hoạt, xử lý tốt các trạng thái trung gian, từ đó cung cấp thông tin đầu vào có ý nghĩa hơn cho quá trình khuyến nghị. Thứ ba, NCF kết hợp Fz học được các mối quan hệ phi tuyến giữa người dùng và hành động, đồng thời điều chỉnh khuyến nghị dựa trên mức độ tâm trạng, mang lại các gợi ý cá nhân hóa phù hợp hơn so với CF truyền thống. Cuối cùng, với chi phí tính toán thấp và khả năng tích hợp mối quan hệ xã hội, GraphMoodRF là một giải pháp thực tế hơn BERT cho các ứng dụng yêu cầu triển khai trên quy mô lớn hoặc tài nguyên hạn chế, chẳng hạn như ứng dụng di động hoặc hệ thống nhúng.

Để tiếp tục cải thiện và mở rộng hệ thống, một số hướng nghiên cứu trong tương lai được đề xuất. Trước hết, có thể tích hợp các mô hình ngôn ngữ lớn như BERT để thay thế TF-IDF trong việc trích xuất đặc trưng ngữ

ngữ từ bài đăng, nhằm nâng cao độ chính xác phân tích tâm trạng. Tiếp theo, việc tự động hóa thiết kế Fz bằng cách sử dụng học máy để học các hàm thành viên và luật mờ từ dữ liệu sẽ tăng tính thích nghi của hệ thống, thay vì phụ thuộc vào thiết kế thủ công. Ngoài ra, mở rộng quy mô tập dữ liệu lên hàng chục nghìn tweet, bao gồm các môi trường mạng xã hội đa dạng như Facebook, Instagram, và các loại tâm trạng phức tạp (ví dụ mĩa mai, hạnh phúc), sẽ giúp phát triển các giải pháp khuyến nghị thích nghi hơn [18,19]. Hơn nữa, tích hợp học tăng cường (Reinforcement Learning) có thể tối ưu hóa khuyến nghị dựa trên phản hồi thực tế của người dùng, thay vì chỉ dựa vào dữ liệu hành vi giả lập. Cuối cùng, để hỗ trợ tốt hơn cho dữ liệu tiếng Việt, hệ thống nên tích hợp các công cụ xử lý ngôn ngữ tự nhiên như underthesea và xây dựng từ điển cảm xúc tiếng Việt [20], từ đó nâng cao khả năng xử lý đa ngôn ngữ. Những hướng phát triển này hứa hẹn sẽ đưa GraphMoodRF trở thành một công cụ mạnh mẽ và toàn diện hơn trong việc hỗ trợ chăm sóc sức khỏe tinh thần.

Lời cảm ơn

Nghiên cứu được tài trợ bởi Trường Đại học Nguyễn Tất Thành, Thành phố Hồ Chí Minh, đề tài mã số 2025.01.132/HĐ-KHCN.

Tài liệu tham khảo

1. Asiedu, G. (2022). Global social media statistics 2022: Usage and trends. *Journal of Digital Communication*, 10(3), 45-60.
2. World Health Organization. (2022). Mental health and COVID-19: Early evidence of the pandemic's impact. *WHO Report*.
3. Kipf, T. N., & Welling, M. (2017). Semi-Supervised Classification with Graph Convolutional Networks. In *Proceedings of the 5th International Conference on Learning Representations (ICLR)*. <https://arxiv.org/abs/1609.02907>
4. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural Collaborative Filtering. In *Proceedings of the 26th International Conference on World Wide Web (WWW)* (pp. 173-182). ACM. <https://doi.org/10.1145/3038912.3052569>
5. Aldkheel, A., & Zhou, L. (2023). Depression detection on social media: A classification framework and research challenges and opportunities. *Journal of Healthcare Informatics Research*, 8(1), 88-120.

6. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL)* (pp. 4171-4186). ACL.
7. Ricci, F., Rokach, L., & Shapira, B. (2011). Introduction to recommender systems handbook. In *Recommender Systems Handbook* (pp. 1-35). Springer.
8. Kaggle. (2020). Mental health social media dataset. <https://www.kaggle.com/datasets/infamouscoder/mental-health-social-media>
9. Mohammad, S. M., & Turney, P. D. (2013). Crowdsourcing a word-emotion association lexicon. *Computational Intelligence*, 29(3), 436-465.
10. Castellano, G., Scaringi, R., & Tedesco, A. (2023). Fuzzy logic and graph neural networks for robust sentiment analysis on social networks. *Expert Systems with Applications*, 213, 119027. <https://doi.org/10.1016/j.eswa.2022.119027>
11. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.
12. Jia, R., Zhou, X., Dong, L., & Pan, S. (2021). Hypergraph convolutional network for group recommendation. In *Proceedings of the 2021 IEEE International Conference on Data Mining (ICDM)* (pp. 245-254). IEEE.
13. Song, S., Shen, L., & Valstar, M. (2023). Human behaviour-based automatic depression analysis using hand-crafted statistics and deep learned spectral features. In *Proceedings of the 13th IEEE International Conference on Automatic Face & Gesture Recognition* (pp. 158-165). IEEE.
14. He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., & Wang, M. (2020). LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation. In *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 639-648). ACM. <https://arxiv.org/abs/2002.02126>
15. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
16. Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys (CSUR)*, 52(1), 1-38.
17. Wang, J., Huang, P., Zhao, H., Zhang, Z., Zhao, B., & Lee, D. L. (2020). Billion-scale recommendation with heterogeneous graph neural networks. In *Proceedings of the 13th International Conference on Web Search and Data Mining (WSDM)* (pp. 672-680). ACM.
18. Li, J., & Sun, M. (2021). Scalable graph neural networks for heterogeneous graphs. In *Proceedings of the 2021 Conference on Neural Information Processing Systems (NeurIPS)* (pp. 15234-15245).
19. Shu, K., Wang, S., Tang, J., Zafarani, R., & Liu, H. (2021). User identity linkage across online social networks: A review. *ACM SIGKDD Explorations Newsletter*, 22(2), 5-17.
20. Nguyen, T. H., Vu, X. L., Nguyen, D. Q., & Nguyen, M. T. (2018). Emotion recognition for Vietnamese social media text. In *Proceedings of the 2018 10th International Conference on Knowledge and Systems Engineering (KSE)* (pp. 121-126). IEEE

Health recommendation system based on sentiment analysis from social media

Pham Dinh Tai

Faculty of Information Technology - Nguyen Tat Thanh University

pdtai@ntt.edu.vn

Abstract This research develops a personalized mental health recommendation system based on emotion analysis from social media. The main goal is to leverage textual data and social relationships to deeply understand users' emotional states, thereby providing suitable recommendations to effectively support mental well-being. GraphMoodRF integrates three main components: Graph Convolutional Network (GCN) to compute the Sentiment Analysis Score (SA Score) from both post content and social network structure; Fuzzy Logic to classify the SA Score into emotional levels such as very negative to very positive; and Neural Collaborative Filtering (NCF) to learn nonlinear relationships between users and recommended actions. Experimental results on 1,000 tweets collected from Twitter show that the system achieves an F1-score of 0.87 in emotion classification and Precision@3 of 0.85 in recommendation tasks, outperforming models like LSTM, BERT, and traditional Collaborative Filtering. The main contribution of this research is to propose a new, effective, and highly scalable model that combines GCN, fuzzy logic, and NCF to personalize recommendations based on emotions. GraphMoodRec has strong potential for real-world applications in platforms that support real-time mental healthcare applications, thus addressing the growing demand for digital mental health interventions.

Keywords Graph Convolutional Network, Neural Collaborative Filtering, Fuzzy Logic, Sentiment Analysis, Recommender System, Social Network.