

# PHÂN TÍCH Ý KIẾN NGƯỜI DÙNG THEO KHÓA CẠNH BẰNG PHƯƠNG PHÁP HỌC SÂU KẾT HỢP CNN-LSTM

Bùi Thanh Hùng, Nguyễn Quốc Bình

Phòng Thí nghiệm Phân tích dữ liệu và Trí tuệ nhân tạo  
Viện Kỹ thuật - Công nghệ  
Đại học Thủ Dầu Một

Số 6 Trần Văn Ôn, Phường Phú Hòa, Thành phố Thủ Dầu Một, Bình Dương, Việt Nam

hungbt.cntt@tdmu.edu.vn, binhngq.bdg@gmail.com

**TÓM TẮT:** Trong cuộc cách mạng 4.0 hiện nay, cùng với sự bùng nổ mạng xã hội và thương mại điện tử, nghiên cứu phân tích ý kiến người dùng theo khía cạnh dần trở thành công cụ quan trọng trong việc phân tích, đánh giá quan điểm người dùng thông qua mạng xã hội, trang mạng bán hàng. Qua phân tích ý kiến người dùng theo khía cạnh, chúng ta sẽ nắm bắt được quan điểm người dùng hoặc khách hàng, cũng như xu hướng chính trị, xã hội xảy ra trong tương lai. Trước đây, nhiều công trình nghiên cứu phân tích ý kiến người dùng theo khía cạnh được thực hiện dựa trên từ vựng, một số dựa vào học máy. Trong những năm gần đây, các mô hình học sâu như mạng nơron tích chập (CNNs), mạng nơron tái phát (RNNs), bộ nhớ ngắn dài (LSTM) đã được áp dụng trong nhiều bài toán và đạt hiệu quả cao. Trong nghiên cứu này, chúng tôi đề xuất phương pháp học sâu kết hợp CNN-LSTM để giải quyết bài toán phát hiện khía cạnh của phân tích ý kiến người dùng theo khía cạnh ở mức tài liệu. Mô hình này kết hợp những tính năng nổi bật của mỗi phương pháp CNN và LSTM, trong đó CNN hoạt động tốt trong trích xuất đặc trưng dữ liệu lớn, còn LSTM hoạt động hiệu quả trong việc phân lớp dữ liệu. Kết quả thực nghiệm trên bộ dữ liệu tiếng Việt VLSP 2018 cho thấy, phương pháp được đề xuất tốt hơn các phương pháp nghiên cứu trước đó nếu chỉ dựa vào một phương pháp đơn lẻ.

**Từ khóa:** Phân tích ý kiến người dùng theo khía cạnh; xác định khía cạnh; học sâu kết hợp; CNN; LSTM; CNN-LSTM.

## I. GIỚI THIỆU

Trong những năm gần đây, phân tích ý kiến người dùng trở thành đề tài nghiên cứu nóng và thu hút nhiều nhà nghiên cứu trong lĩnh vực ngôn ngữ tự nhiên. Nghiên cứu phân tích ý kiến người dùng được xem là phương tiện trung gian để hai bên cung - cầu gặp nhau. Đối với khách hàng, hệ thống phân tích có thể giúp lựa chọn sản phẩm và dịch vụ tin cậy. Đối với nhà sản xuất, hệ thống giúp họ đánh giá chỗ đứng sản phẩm trên thị trường, am hiểu khách hàng, cũng như xu hướng khách hàng. Từ đó, giúp nhà sản xuất đưa ra chiến lược hợp lý.

Phân tích ý kiến người dùng theo khía cạnh giúp chúng ta phân tích chuyên sâu, hiểu sâu sắc và xác định ý kiến người dùng theo các khía cạnh đánh giá khác nhau. Ba vấn đề cơ bản trong phân tích ý kiến người dùng theo khía cạnh là phát hiện khía cạnh (Aspect Detection), biểu diễn quan điểm (Opinion Target Expression) và phân cực ý kiến (Sentiment Polarity) [1-2]. Nghiên cứu này nhằm mục đích đề xuất một phương pháp học sâu kết hợp để phát hiện khía cạnh ở mức tài liệu cho miền dữ liệu nhà hàng, tự động phát hiện các khía cạnh quan trọng trong ý kiến của người dùng.

Giả sử đưa ra một tập hợp các đánh giá của khách hàng  $D (d_1, d_2, \dots, d_n)$  về một thực thể xác định (ví dụ: một nhà hàng), mục tiêu là xác định một tập hợp các khía cạnh được chỉ định các cặp  $(E \# A)$  - trong đó  $E$  là thực thể (ví dụ: thức ăn, đồ uống, địa điểm,...) và  $A$  là thuộc tính của thực thể (ví dụ: Giá cả, chất lượng, ...), điều này hướng tới sẽ giúp xác định ý kiến người dùng theo khía cạnh được thể hiện trong một câu nhất định.

Có nhiều phương pháp giải quyết bài toán phân tích ý kiến người dùng theo khía cạnh và học máy là một phương pháp được nhiều nhà nghiên cứu sử dụng vì đem lại hiệu quả tốt. Phương pháp học máy cho bài toán Phân tích ý kiến người dùng theo khía cạnh có thể chia làm 3 nhóm chính: học có giám sát [3-4], phương pháp học không được giám sát [5] và học bán giám sát [6-8].

Gần đây, phương pháp học sâu được áp dụng rất thành công trong xử lý ngôn ngữ tự nhiên (NLP), đặc biệt trong lĩnh vực phân tích ý kiến người dùng sử dụng mô hình CNN [9-10], LSTM [11-12]. Mỗi tác giả có kỹ thuật phân tích khác nhau. Tác giả Taboada gắn nhãn ý kiến người dùng lên văn bản bằng cách trích xuất những từ ý kiến người dùng [13]. Bing Liu định hình phân tích ý kiến người dùng như là một nhiệm vụ phân lớp và ứng dụng những kỹ thuật máy học có giám sát vào bài báo [3]. Gần đây, phương pháp học sâu đã cung cấp cách tiếp cận mới thông qua biểu diễn véc-tơ (biểu diễn các từ thành véc-tơ để tìm điểm tương đồng) đã đưa nghiên cứu phân tích ý kiến người dùng phát triển bước mới. Bengio và Mikolov trình bày các kỹ thuật học thuật đối với sự diễn đạt ý kiến người dùng [14-15]. Các tác giả sử dụng từ những véc-tơ chứa đựng ý kiến người dùng bằng cách sử dụng mạng nơron để dự đoán ý kiến người dùng. Theo đó, các từ những véc-tơ sẽ gần nhau nếu chúng cùng nghĩa. Yessenalina và Cardie định hình mỗi từ như một ma trận và dùng phương pháp nhân ma trận lặp đi lặp lại để diễn đạt một cụm từ. Le và Mikolov áp dụng mẫu tin vào kỹ thuật những từ để diễn đạt ý kiến người dùng [16]. Còn Tang dùng CNN hoặc LSTM để diễn đạt câu và mã hóa véc-tơ ý kiến người dùng trong văn bản [17].

Trong bài báo này, chúng tôi đi sâu vào 3 mô hình cụ thể: CNN, LSTM và CNN-LSTM để phân tích ý kiến người dùng theo khía cạnh. Nếu CNN có khả năng trích xuất thông tin địa phương giữa các từ lân cận nhưng có thể không nắm bắt được sự phụ thuộc vào khoảng cách dài ngắn của các từ trong mỗi khía cạnh (không chính xác đối với

các cụm từ có khoảng cách xa). Thì LSTM có thể giải quyết hạn chế này bằng cách mô hình hóa các văn bản theo thứ tự qua các từ trong mỗi khía cạnh. Vì lý do trên, chúng tôi đề xuất mô hình kết hợp 2 mô hình trên để bài toán đạt hiệu quả bằng cách kết hợp giữa CNN và LSTM, cả thông tin địa phương trong các khía cạnh và sự phụ thuộc về khoảng cách dài ngắn của các từ trong khía cạnh có thể được xem xét trong quá trình dự đoán. Phần còn lại của bài báo được tổ chức như sau. Phần II mô tả mô hình học sâu kết hợp CNN-LSTM. Phần III báo cáo kết quả đánh giá của phương pháp được đề xuất bằng dữ liệu thực tế. Kết luận cuối cùng được trình bày trong Phần IV.

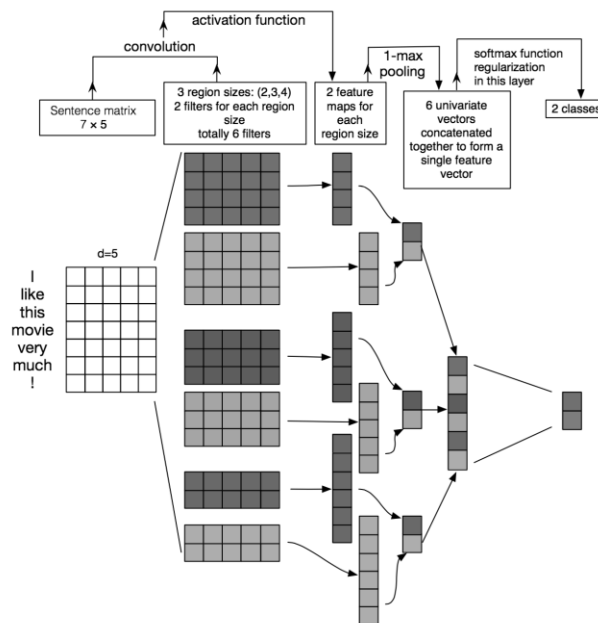
## II. MÔ HÌNH ĐỀ XUẤT

Như phần trình bày trên, chúng tôi đề xuất mô hình kết hợp CNN-LSTM để phân tích ý kiến người dùng theo khía cạnh đạt hiệu quả cao. Trong phần tiếp theo, chúng tôi trình bày khái quát mô hình học sâu CNN, LSTM, cũng như mô hình học sâu kết hợp CNN-LSTM.

### 2.1. Mô hình mạng nơron tích chập - Convolutional Neural Network (CNN)

Mô hình CNN thường được sử dụng để trích xuất đặc trưng dữ liệu hình ảnh và CNN cũng hoạt động tốt với dữ liệu văn bản. Đối với các bài toán xử lý ngôn ngữ tự nhiên là các câu hoặc các văn bản được biểu diễn dưới dạng ma trận. Mỗi dòng của ma trận biểu diễn là một véc-tơ biểu diễn một đơn vị, thường là từ, nhưng cũng có thể là một ký tự. Nghĩa là, mỗi dòng là một véc-tơ đại diện cho một từ. Thông thường, các véc-tơ này là các biểu diễn đặc trưng của từ, hoặc cũng có thể là các véc-tơ một điểm nóng (one-hot véc-tơ) đánh chỉ mục các từ thành một từ điển. Ví dụ với câu dài 10 từ sử dụng 100 chiều ta có dữ liệu đầu vào là ma trận  $10 \times 100$ .

Trong thị giác máy tính, các bộ lọc trượt trên từng mảng của bức ảnh, còn trong xử lý ngôn ngữ tự nhiên sẽ dùng các bộ lọc trượt qua độ rộng của ma trận (các từ), theo thứ tự từ trái qua phải, từ trên xuống dưới. Hình 1 mô tả quá trình áp dụng CNN vào bài toán phân tích ý kiến người dùng. Các đặc trưng được rút trích theo từng nhóm các từ gần nhau theo không gian, thay vì tuần tự theo thời gian.




Hình 1. Mô hình áp dụng CNN vào bài toán phân tích ý kiến người dùng

Trong hình trên, ta chọn 3 kích cỡ của bộ lọc là 2, 3, 4, mỗi giá trị có 2 bộ lọc. Mỗi bộ lọc thực hiện tích chập trên 1 ma trận câu và tạo ra các ảnh xạ đặc trưng khác nhau. Sau đó hàm tổng hợp lớn nhất được thực hiện cho mỗi ảnh xạ, lưu lại giá trị lớn nhất trong mỗi ảnh xạ đặc trưng và 6 đặc trưng được ghép lại thành 1 véc-tơ đặc trưng cho tầng áp chót. Tầng softmax cuối cùng sẽ nhận các véc-tơ đặc trưng này thành đầu vào và dùng nó để phân loại câu, sau đó trả về 2 trạng thái kết quả.

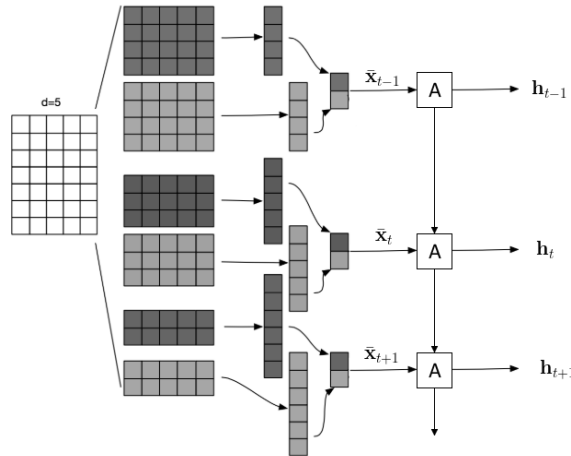
### 2.2. LSTM

Với mỗi câu dữ liệu là một dãy các chữ trong từ điển. Ta sẽ biểu diễn các chữ thành các biểu diễn từ nhúng, thể hiện mối quan hệ của các từ với nhau. Lúc này ta có một mảng của các véc-tơ dữ liệu (tức là một ma trận). Ta sẽ lần lượt xem mỗi véc-tơ ấy như là một thời điểm của câu dữ liệu và truyền vào tương ứng chữ thứ  $i$  là thời điểm  $t_i$  từ đầu câu đến cuối câu. Kết quả sau khi truyền hết chữ cuối cùng sẽ được truyền vào một tầng cuối cùng gồm 1 nút, có hàm kích hoạt là sigmoid (để giá trị cho vào khoảng). Giá trị đó cũng sẽ là kết quả của dự đoán. Hình 2 mô tả mô hình LSTM áp dụng vào bài toán Phân tích ý kiến người dùng.



Hình 2. Mô hình áp dụng của LSTM vào bài toán phân tích ý kiến người dùng với ví dụ câu gồm 4 từ

2.3. Mô hình học sâu kết hợp CNN-LSTM



Hình 3. Mô hình học sâu kết hợp CNN-LSTM

Phương pháp học sâu kết hợp kết hợp các ưu điểm của mô hình CNN và LSTM do Donahue et al đề xuất ban đầu [18]. Chúng tôi xây dựng mô hình học sâu kết hợp dựa trên [18-19]. Hình 3 trình bày sơ đồ tổng thể của mô hình đề xuất CNN-LSTM. Trong mô hình kết hợp CNN-LSTM, mạng CNN rút trích đặc trưng, sau đó LSTM dự đoán theo thứ tự các đặc trưng ấy. Nếu ta áp dụng CNN để rút trích ra đặc trưng và sau đó truyền đặc trưng lần lượt vào LSTM để tính kèm theo thông tin về thứ tự của chúng, thì ta sẽ được một mô hình ghép kết hợp được ưu điểm của cả hai mô hình học sâu.

Trong mô hình kết hợp CNN-LSTM cho bài toán phát hiện khía cạnh trong phân tích ý kiến người dùng theo khía cạnh, CNN sẽ rút trích đặc trưng theo khía cạnh từ dữ liệu đầu vào là từ nhúng của các từ và LSTM sẽ phân lớp khía cạnh từ các đặc trưng đó.

III. THỰC NGHIỆM

Chúng tôi đánh giá hiệu suất của mô hình kết hợp CNN-LSTM được đề xuất dựa trên so sánh kết quả với phương pháp chỉ sử dụng một mô hình học sâu. Mô hình đề xuất này được thực nghiệm trên bộ dữ liệu VLSP 2018 [20]. Bộ dữ liệu bao gồm các đánh giá ở mức tài liệu được thu thập và gán nhãn giống như trong các cuộc thi của SemEval [1]. Bảng 1 trình bày cụ thể về bộ dữ liệu VLSP 2018. Tham số của các mô hình học sâu được trình bày chi tiết trong Bảng 2. Các mô hình được cài đặt bằng ngôn ngữ lập trình Python, sử dụng thư viện Keras, hỗ trợ Tensorflow. Chúng tôi sử dụng từ nhúng tiếng Việt FastText với số chiều là 300 của nhóm nghiên cứu Facebook AI Research. Phân tách từ và tiền xử lý chúng tôi dùng các thư viện hỗ trợ BeautifulSoup, pyvi (tách từ cho tiếng Việt), và Tokenizer (của phần tiền xử lý Keras) và sử dụng stopwords (danh sách từ không có ý nghĩa do dùng quá nhiều) của Lê Văn Duyệt (2015).

Bảng 1. Chi tiết về bộ dữ liệu VLSP 2018

Miền dữ liệu	Dữ liệu huấn luyện	Dữ liệu kiểm thử	Dữ liệu kiểm tra
RESTAURANT	2,961	1,290	500
HOTEL	3,000	2,000	600

Bảng 2. Chi tiết về các tham số của các mô hình huấn luyện

Tên mô hình	CNN	LSTM	CNN-LSTM
Các tham số	32 Conv1D 32 MaxPool 0.2 Dropout 250 Dense	0.2 Dropout 100 LSTM 0.2 Dropout	32 Conv1D 32 MaxPool 0.2 Dropout 100 LSTM

Để đánh giá kết quả, chúng tôi dùng độ đo F1 score, F1 score được tính theo các công thức dưới đây:

$$\text{Precision}_{\text{Micro}} = \frac{\sum_{c_i \in C} TP_{c_i}}{\sum_{c_i \in C} (TP_{c_i} + FP_{c_i})}$$

$$\text{Recall}_{\text{Micro}} = \frac{\sum_{c_i \in C} TP_{c_i}}{\sum_{c_i \in C} (TP_{c_i} + FN_{c_i})}$$

$$\text{F1 - score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

Trong đó TP (Tích cực đúng) nghĩa là số lượng đánh giá được chỉ định chính xác cho lớp  $c_i$ , FP (Tích cực sai) có nghĩa là số lượng đánh giá được chỉ định không chính xác đối với lớp  $c_i$ , FN (Sai phủ định) có nghĩa là số đánh giá nên được chỉ định lớp  $c_i$  nhưng không được dự đoán,  $c_i$  là lớp thứ  $i$  trong số lớp  $C$  cho mỗi miền. Kết quả của các mô hình trên 2 bộ dữ liệu RESTAURANT và HOTEL của VLSP 2018 được trình bày trong các Bảng 3 và Bảng 4.

Bảng 3. So sánh kết quả của các phương pháp khác nhau trên bộ dữ liệu RESTAURANT

Mô hình	Precision	Recall	F1-score
CNN	0,78	0,74	0,759
LSTM	0,72	0,68	0,699
<b>CNN-LSTM</b>	<b>0,81</b>	<b>0,78</b>	<b>0,795</b>

Bảng 4. So sánh kết quả của các phương pháp khác nhau trên bộ dữ liệu HOTEL

Mô hình	Precision	Recall	F1-score
CNN	0,84	0,56	0,672
LSTM	0,76	0,52	0,618
<b>CNN-LSTM</b>	<b>0,87</b>	<b>0,58</b>	<b>0,696</b>

Bảng 3 trình bày kết quả so sánh của mô hình kết hợp CNN-LSTM đối với một số mô hình chỉ sử dụng một phương pháp học sâu CNN, LSTM để đánh giá độ chính xác trên dữ liệu RESTAURANT. Mô hình CNN cho kết quả tốt hơn mô hình LSTM và mô hình CNN-LSTM cho kết quả cao hơn so với 2 mô hình độc lập CNN, LSTM.

Bảng 4 trình bày kết quả của các mô hình trên bộ dữ liệu HOTEL. Kết quả cũng cho thấy mô hình kết hợp CNN-LSTM cho kết quả tốt nhất. Điều này chứng tỏ mô hình ghép đôi CNN-LSTM đạt hiệu quả hơn các mô hình còn lại.

#### IV. KẾT LUẬN

Trong nghiên cứu này, chúng tôi đã trình bày một mô hình kết hợp CNN-LSTM cho bài toán phát hiện khía cạnh trong phân tích ý kiến người dùng theo khía cạnh đạt độ chính xác cao và hiệu quả. Qua thực nghiệm cho thấy, mô hình kết hợp CNN-LSTM đạt được kết quả tốt nhất so với các mô hình học sâu độc lập CNN, LSTM. Trong thời gian tới, chúng tôi sẽ nghiên cứu tích hợp các đặc trưng ngôn ngữ với từ nhúng và tìm cách cải tiến mô hình để đạt hiệu quả tốt hơn, cũng như sử dụng kết quả trong giải quyết các bài toán khác của xử lý ngôn ngữ tự nhiên. Đồng thời chúng tôi cũng sẽ thử nghiệm trên các mô hình học sâu khác nhau để từ đó so sánh, đánh giá, tìm ra mô hình tối ưu cho bài toán phân tích ý kiến người dùng theo khía cạnh.

#### TÀI LIỆU KHAM KHẢO

- [1] M. Pontiki, D. Galanis, H. Papageorgiou, I. Androutsopoulos, S. Manandhar, M. Al-Smadi, M. Al-Ayyoub, Y. Zhao, B. Qin, O. D. Clercq, V. Hoste, M. Apidianaki, X. Tannier, N. Loukachevitch, E. Kotelnikov, N. Bel, S. M. JiménezZafra, and G. Eryigit. "SemEval-2016 Task 5: Aspect Based - Sentiment Analysis". In Proceedings of the 10<sup>th</sup> International Workshop on Semantic Evaluation, ser. SemEval'16, Association for Computational Linguistics, 2016.
- [2] H G. Qiu, B. Liu, J. Bu, and C. Chen. "Opinion Word Expansion and Target Extraction through Double Propagation". Computational Linguistics, Vol. 37, No. 1, 9-27, 2011.
- [3] B. Liu. "Sentiment Analysis and Opinion Mining". Synthesis Lectures on Human Languages Technologies, Morgan and Claypool publishers, 2012.
- [4] D. Bespalov, B. Bai, Y. Qi, and A. Shokoufandeh. "Sentiment Classification Based on Supervised Latent N-gram Analysis". In Proceedings of CIKM, pp. 375-382, 2011.
- [5] R. Socher, A. Perelygin, J. Y. Wu, J. Chuang, C. Manning, A. Ng, and Christopher Potts. "Recursive Deep Models for Semantic Compositionality Over a Sentiment Treebank". In Proceedings of EMNLP, pp. 1631-1642, 2013.
- [6] J. Rothfels and J. Tibshirani. "Unsupervised Sentiment Classification of English Movie Reviews using Automatic Selection of Positive and Negative Sentiment Items". Technical Report, Stanford University, 2010.

- [7] S. Li, Z. Wang, G. Zhou, and S. Y. M. Lee. “Semi-Supervised Learning for Imbalanced Sentiment Classification”. In Proceedings of the International Joint Conference on Artificial Intelligence (IJCAI), pp. 1826-1831, 2011.
- [8] R. Socher, J. Pennington, E. H. Huang, A. Ng, and C. Manning. “SemiSupervised Recursive Autoencoders for Predicting Sentiment Distributions”. In Proceedings of EMNLP, pp. 151-161, 2011. [22] O. Tackstrom and R. McDonald. Semi-supervised Latent Variable Models for Sentence-level Sentiment Analysis. In Proceedings of ACL, pp. 569-574, 2011.
- [9] Kim, Yoon. “Convolutional neural networks for sentence classification”. arXiv preprint arXiv: 1408.5882, 2014.
- [10] Zhang, Ye, and Byron Wallace. “A Sensitivity Analysis of Convolutional Neural Networks for Sentence Classification”. arXiv preprint arXiv: 1510.03820, 2015.
- [11] Xin Wang, Yuanchao Liu, Chengjie Sun, Baoxun Wang, Xiaolong Wang. “Predicting Polarities of Tweets by Composing Word Embeddings with Long Short-Term Memory”. ACL, 2015.
- [12] Liu, Pengfei, Shafiq R. Joty, and Helen M. Meng. “Fine-grained Opinion Mining with Recurrent Neural Networks and Word Embeddings”. EMNLP, 2015.
- [13] Maite Taboada, Julian Brooke, Milan Tofiloski, Kimberly Voll, and Manfred Stede. “Lexiconbased Methods for Sentiment Analysis, Computational linguistics”, 37(2): 267-307, 2011.
- [14] Yoshua Bengio, Rejean Ducharme, Pascal Vincent, and Christian Jauvin. “A Neural Probabilistic Language Model. Journal of machine learning research”, 3(Feb):1137-1155, 2003.
- [15] Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. “Efficient Estimation of Word Representations in Vector Space”. arXiv preprint arXiv: 1301.3781, 2013.
- [16] Quoc V Le and Tomas Mikolov. “Distributed Representations of Sentences and Documents”. In ICML, Vol. 14, pp. 1188-1196, 2014.
- [17] Duyu Tang, Bing Qin, and Ting Liu. “Document Modeling with Gated Recurrent Neural Network for Sentiment Classification”. In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, pp. 1422-1432, 2015.
- [18] Donahue J., Hendricks L.A., Rohrbach M., Venugopalan S., Guadarrama S., Saenko K., Darrell T. “Long-term recurrent convolutional networks for visual recognition and description”. IEEE Trans. Pattern Anal. Mach. Intell. 39, 677-691, 2017.
- [19] Bui Thanh Hung. “Vietnamese Keyword Extraction Using Hybrid Deep Learning Methods”. In proceedings of the 5th NAFOSTED Conference on Information and Computer Science, 2018.
- [20] <https://vlsp.org.vn/vlsp2018>.

## ASPECT-BASED SENTIMENT ANALYSIS USING HYBRID DEEP LEARNING APPROACH CNN-LSTM

Bui Thanh Hung, Nguyen Quoc Binh

**ABSTRACT:** *With the rise of the Industrial revolution 4.0, along with the rapid growth of social networks and E-commerce, aspect-based sentiment analysis has gradually become a vital tool to analyze and evaluate the customers' feedback through social networking platforms or online sales websites. By analyzing the customer feedback in terms of aspects, we could capture the customer insights as well as political opinions and predict the future social trends. In the past, many researches analyzing aspect-based sentiment were done based on linguistic while some were based on machine learning. Nowadays, deep learning models such as Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and Long Short Term Memory (LSTM) are being used for this technique and it has achieved higher efficiency. In this research, we propose a hybrid deep learning method combining CNN-LSTM to solve the aspect detection problem of aspect-based sentiment analysis at document level. This model combines the advantages of each of the CNN and LSTM methods, in which CNN works well in extracting spartial features, while LSTM works effectively in data classification. Experimental results on the Vietnamese VLSP 2018 dataset show that the proposed method achieves better results than the previous research methods if it only relies on a single method.*