

## MODELO DE CLASSIFICAÇÃO DE PATENTES BASEADO EM TÉCNICAS DE ENGENHARIA DO CONHECIMENTO

Luciano Zamperetti Wolski<sup>1</sup>;  
Willian Aurélio Pizoni<sup>2</sup>;  
Alexandre Leopoldo Gonçalves<sup>3</sup>.

**Abstract:** *Annually, a large volume of patents is deposited in patent offices worldwide. In this sense, automatic patent classification is essential to assist examiners in decision making. The main goal of this paper is to propose a model towards the patent classification, taking into account aspects of classes ranking and explanation through knowledge graph. The proposed model was evaluated using a public dataset, as well as three neural network architectures. So far, the aggregate accuracy for the ranking at position  $k=5$  has reached around 75% for the three neural networks. In this sense, from the preliminary results obtained, it is possible to verify that the model has conditions to assist examiners in choosing classes that best represent a given patent.*

**Keywords:** *Patent Analysis; Patent Classification; Deep Learning; Knowledge Graph.*

**Resumo:** *Anualmente, um grande volume de patentes é depositado nos escritórios de patentes no mundo todo. Neste sentido, a classificação automática de patentes é fundamental para auxiliar os examinadores na tomada de decisão. O objetivo deste artigo é propor um modelo voltado à classificação de patentes a partir de fonte de dados não estruturados na forma de texto levando-se em conta aspectos de ordenação e explicação das classes sugeridas por meio de grafos de conhecimento. O modelo proposto foi avaliado utilizando-se um conjunto de dados público, bem como três arquiteturas de redes neurais. Até o momento a acurácia agregada para o ranking na posição  $k=5$  atingiu em torno de 75% para as três redes neurais. Neste sentido, a partir dos resultados preliminares obtidos, é possível verificar que o modelo possui condições de auxiliar examinadores na escolha de classes que melhor representem determinada patente.*

---

<sup>1</sup> Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0003-4683-1013>. e-mail: [lwolski@gmail.com](mailto:lwolski@gmail.com)

<sup>2</sup> Curso de Graduação em Engenharia da Computação – Universidade Federal de Santa Catarina (UFSC) Araranguá – Brasil. ORCID: <https://orcid.org/0000-0001-5757-3967>. e-mail: [willianaureliop@gmail.com](mailto:willianaureliop@gmail.com)

<sup>3</sup> Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-6583-2807>. e-mail: [a.l.goncalves@ufsc.br](mailto:a.l.goncalves@ufsc.br)

*Palavras-chave: Análise de Patentes; Classificação de Patente; Aprendizado Profundo; Grafo de Conhecimento.*

## 1. INTRODUÇÃO

Os pedidos de patentes crescem anualmente e, segundo os indicadores da WIPO (2021), em 2020 foram 3,3 milhões de pedidos de patentes em todo o mundo, representando um aumento de 1,6% em relação a 2019. Esses pedidos de patentes acabam produzindo grandes coleções de textos que representam uma extensa quantidade de conhecimento humano, geralmente na forma não estruturada (Risch & Krestel, 2019).

Todo esse conhecimento humano aplicado em um pedido de patente deve ser depositado em algum escritório de patentes espalhado por diversos países. Os escritórios de patentes fazem uma análise do pedido e, se todas as regras estipuladas forem atendidas, a patente é concedida.

Com o crescente aumento no número de pedidos de patentes depositados anualmente, as atividades exercidas pelos examinadores de patentes também cresceram. Com isso, os examinadores são sobrecarregados, pois uma das primeiras tarefas é atribuir manualmente códigos de classificação a essas patentes com base em seu conteúdo técnico (Sofean, 2021).

Desta forma, assegura-se que as patentes e pedidos de patentes com características semelhantes, que tratem de temas similares ou em áreas tecnológicas específicas, sejam agrupados sob os mesmos códigos. A correta classificação de documentos de patentes é de extrema importância para a interoperabilidade entre diferentes escritórios de patentes e para a realização de tarefas confiáveis de busca, gerenciamento e recuperação, durante um procedimento de pedido de patente (Gomez & Moens, 2014).

O sistema de classificação utilizado pela maioria dos escritórios de patentes é o *International Patent Classification* (IPC), estabelecida pelo Acordo de Estrasburgo no ano de 1971. O IPC consiste de um sistema hierárquico que divide as tecnologias em oito classes que vão de A a H e cerca de 75.000 subdivisões, cada uma representada por um símbolo que consiste em caracteres do alfabeto latino e algarismos arábicos (WIPO, 2022).

O IPC classifica sistematicamente as patentes em subclasses auxiliando na recuperação de documentos semelhantes que pode ser realizada através da busca por patentes na mesma subclasse. Entretanto, realizar a classificação de patentes manualmente se torna dispendioso aos examinadores e requer conhecimento específico do domínio devido à complexidade do IPC (Risch & Krestel, 2019).

Neste sentido, a inteligência artificial por meio de técnicas de aprendizado de máquina e, mais recentemente, o aprendizado profundo combinado com redes neurais estão entre as abordagens mais utilizadas para solucionar as mais variadas tarefas na análise de patentes, em especial a classificação de patentes. O uso de sistemas automatizados de classificação de patentes pode ser muito eficaz, uma vez que suportam uma variedade de atividades de inovação tecnológica, incluindo examinar, detectar e reduzir a possibilidade de violação de patentes (Yun & Geum, 2020).

No entanto, quanto maior o volume de patentes, mais complexo se torna o processo de classificação. Segundo (Gomez & Moens, 2014), quando se tem muitas patentes para gerenciar, a estrutura de classificação deve ser muito bem organizada e detalhada para facilitar a classificação, a navegação e a busca precisa. Além disso, como as patentes refletem de alguma forma o conhecimento tecnológico do mundo e, esse conhecimento muda ao longo do tempo, a estrutura de classificação também deve ser flexível o suficiente para capturar tais mudanças.

A classificação de patentes, enquanto tarefa, possui vários desafios que impactam diretamente na tomada de decisão pelos examinadores. Com isso, a classificação de patentes, caso forneça os elementos adequados, pode auxiliar no aumento da qualidade da tomada de decisão (Jafery, Omar, Ahmad, & Ithnin, 2019).

Diante do contexto apresentado, surge o seguinte problema de pesquisa: como auxiliar a análise de patentes, mais especificamente a tarefa de classificação, por meio de elementos que explicitem o conhecimento latente presente nas bases de patentes?

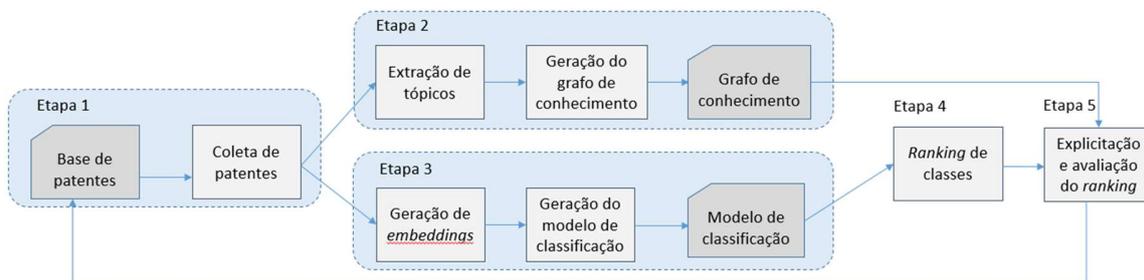
Isto posto, apresenta-se neste estudo um modelo voltado a classificação de patentes a partir de texto levando-se em consideração aspectos de ordenação de classes e explicitação de conhecimento. Para isso o modelo proposto estabelece uma combinação de técnicas de

processamento de linguagem natural (PLN), representação do conhecimento e aprendizagem profunda para auxiliar no processo de classificação de patentes. Mais especificamente, contribuir com o processo de tomada de decisão, de tal maneira que, a tarefa de classificação no contexto de análise de patentes seja facilitada.

## 2. MODELO PROPOSTO

O modelo proposto compreende uma série de etapas, com base na revisão da literatura e fundamentação teórica, com a finalidade de responder a pergunta de pesquisa e atingir o objetivo desta pesquisa. A seguir serão apresentadas as etapas do modelo com uma breve descrição, conforme a *Figura 1*.

Figura 1: Etapas do modelo proposto



Fonte: Elaborada pelo autor (2021)

O modelo proposto é voltado a sugestão de classes e subclasses de patentes a partir de fontes de dados não estruturados na forma de texto levando-se em consideração aspectos de ordenação de subclasses (*ranking*) e explicitação do conhecimento. Em outras palavras, o *ranking* deve promover subsídios para o examinador de patentes indicando quais são as subclasses com maior relevância para serem atribuídas a determinada patente, auxiliando na tomada de decisão.

A Etapa 1 consiste na escolha de uma base de patentes disponível para realização de testes em formato não estruturada. A coleta de patentes pode ocorrer a partir de diversas

fontes, entre elas, a base de patentes disponibilizada pelo USPTO<sup>®</sup>. Após a coleta torna-se requerida a realização do pré-processamento, por exemplo, a retirada de *stopwords* e aplicação de lematização.

Na Etapa 2, a partir da base de patentes obtida na etapa 1, são extraídos os tópicos mais relevantes que servirão de entrada para a geração do grafo de conhecimento. O grafo de conhecimento possui como função essencial a explicitação do conhecimento envolto nas sugestões de classes a partir de determinada patente de interesse.

Já na Etapa 3, os dados coletados são transformados em vetores densos (*embeddings*) de documentos. Os *embeddings* de documentos são representados na forma de um vetor de características com  $n$ -dimensões. De modo geral, servem de base para gerar o modelo de classificação que utiliza, por exemplo, uma rede neural para representar os dados de texto, capturando a semântica de palavras e documentos. Como resultado tem-se um modelo de classificação na sua essência, mas com um viés de sugestão de classes em que cada classe possui uma probabilidade associada criando subsídios para a ordenação (*ranking*) do resultado.

Na Etapa 4, o *ranking* de classes de patentes é produzido sob demanda, ou seja, é ativado a partir da demanda de avaliação de alguma nova patente. O *ranking* representa a ordenação das classes de patentes geradas no modelo de classificação, ou seja, apresenta as classes mais prováveis para uma determinada patente indo da classe mais provável para a menos provável.

Por fim, a Etapa 5 possui como objetivo a explicitação e inspeção do *ranking* por meio de grafos de conhecimento (KG). No modelo, o KG representa as classes de patentes e como estas se interconectam através dos tópicos extraídos a partir das patentes com o intuito de promover meios de entendimento das sugestões ordenadas de classes através de uma representação visual. Neste sentido, este contexto visa prover ferramental relevante aos examinadores de modo a reduzir o tempo de avaliação de uma patente e aumentar a acurácia, ou seja, objetiva fornecer subsídios para decisões mais assertivas. Como ação final, determinada patente retorna para a base agora com as classes escolhidas pelo examinador,

impactando na atualização do modelo de classificação e no grafo de conhecimento, permitindo a evolução das classificações/recomendações ao longo do tempo.

### 3. RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados preliminares utilizando parte do conjunto de dados da USPTO, assim como uma métrica para avaliar o desempenho do modelo proposto em experimentos iniciais. A análise dos resultados preliminares resume-se em discutir a instanciação do modelo utilizando *embeddings* de documento como técnica de representação vetorial, assim como observar a viabilidade da utilização de algumas arquiteturas de redes neurais na sugestão de subclasses de maneira ordenada. Ademais, concentra-se na utilização de grafos de conhecimento com o intuito de auxiliar no entendimento de maneira visual das classes sugeridas. A atualização das ações efetuadas pelos examinadores, no sentido da escolha das melhores classes/subclasses para determinada patente e, conseqüente, atualização da base de dados e outros elementos do modelo, não serão avaliadas neste trabalho.

Neste sentido, foram utilizadas três arquiteturas de redes neurais: MLP, CNN e LSTM. A partir das redes neurais apresentadas foi possível realizar a instanciação e execução de parte do modelo proposto. A execução foi realizada obedecendo as configurações, apresentadas no Quadro 2.

Para a avaliação do modelo proposto utilizou-se o conjunto de dados USPTO-2M, composto por mais de 2 milhões de patentes dos EUA, referentes aos anos de 2006 a 2015 (Li et al., 2018), contendo título, resumo e as subclasse(s) que determinada patente possui. A partir deste conjunto foram identificados as 50 subclasses mais frequentes no conjunto de dados USPTO-2M, sendo então separados 1000 patentes para cada uma das subclasses, totalizando 50 mil patentes. Destas, 40 mil representam o conjunto de treinamento e 10 mil o conjunto de teste. Com os conjuntos de dados (treinamento e teste) definidos foram testas três arquiteturas de redes neurais: MLP, CNN e LSTM.

Considerando as configurações apresentadas acima, foram realizadas as avaliações com o conjunto de teste, sendo que os resultados obtidos apresentados no Quadro 1.

Quadro 1: Resultados preliminares da avaliação de redes neurais

Ranking	Acurácia		
	CNN	LSTM	MLP
1	39,87%	38,19%	39,42%
2	55,55%	53,00%	53,48%
3	64,97%	62,48%	62,50%
4	71,90%	69,40%	68,58%
5	77,08%	74,43%	73,58%
6	80,64%	78,24%	76,90%
7	83,28%	81,00%	79,97%
8	85,55%	83,22%	82,10%
9	87,35%	85,20%	84,26%
10	88,80%	87,03%	85,91%

Fonte: Elaborada pelo autor (2022)

Os resultados preliminares, dispostos no quadro acima, indicam a acurácia do *ranking* para as  $n=10$  (*top 10*) classes mais relevantes sugeridas. Neste sentido, considerando determinada patente na etapa de teste apresentada ao modelo de classificação e, levando-se em conta a primeira classe sugerida (*ranking* igual a 1), tem-se uma acurácia para cada uma das redes. O mesmo vale para os demais *rankings*. Como os resultados obtidos para as três redes neurais são próximos, para efeito de análise preliminar será discutido os resultados da rede CNN que obteve um desempenho levemente superior as demais.

Para cada patente apresentada à rede neural obtém-se uma lista de classes ordenadas pela probabilidade de cada classe. De modo geral, esta probabilidade pode ser entendida como uma medida de relevância na classe, permitindo o estabelecimento do *ranking*. Vale lembrar que cada instância de patente do conjunto de teste possui uma ou mais subclasses associadas.

Neste sentido, ao se considerar como resposta correta somente a primeira subclasse, tem-se um percentual de acertos de 39,87%. Como determinada patente pode ter mais de uma

classe associada, caso uma patente de entrada tenha duas classes, uma delas pode estar dentro do *ranking*, neste caso *top 1*, e a outra não. Isto justifica em parte a baixa acurácia para as primeiras posições do *ranking*.

Seguindo está lógica, à medida que mais subclasses são consideradas, ou seja, a medida que se aumenta a ordem do *ranking*, aumenta-se também a acurácia. Isto promove mais chances de localizar determinada classe da patente na lista ordenada a ser provida ao examinador.

Neste sentido, percebe-se pelo Quadro 1 que a probabilidade da subclasse associada a uma patente estar na segunda posição atinge 55,55%. Pensando em um cenário mais próximo da aplicação real do modelo, pelo menos 5 (cinco) subclasses seriam ofertadas para determinado examinador analisar. Sendo assim, torna-se mais provável que entre as 5 (cinco) primeiras classes, exista pelo menos uma classe que poderia ser vinculada a patente que está sendo analisada. Esta situação em particular atingiu uma acurácia de 77,08%.

Para clarificar o funcionamento do processo de ordenação de subclasses (*ranking*), o Quadro 2 apresenta um exemplo de patente extraída do conjunto de teste da rede neural CNN. A patente possui uma classe H04 e duas subclasses, representadas por H04J e H04W, sem qualquer tipo de ordenação.

Quadro 2: Patente de exemplo

Campos	Conteúdo
Título	mobile station radio base station communication control method and mobile communication system
Resumo	a mobile station according to the present invention includes a packet discarder unit configured to discard a packet in an uplink transmission buffer after assigning a sequence number to the packet when a predetermined condition is met.
Classe	H04J, H04W (ordem que aparece no conjunto de dados sem qualquer indicação de relevância)

Fonte: Elaborada pelo autor (2022)

O resultado da execução da etapa de teste da patente de exemplo é apresentado no Quadro 3. Com base na rede neural CNN, tem-se a ordenação para as 10 (dez primeiras) classes da patente de exemplo. A rede CNN classificou a subclasse H04W com uma probabilidade de 0,4008 (40%), indicando a subclasses mais relevantes. Já a probabilidade de acerto da subclasse H04J foi de 20,4753%. As probabilidades são geradas para as 50

subclasses que determinada patente, neste estudo, pode possuir, sendo que a soma dessas probabilidades é igual a 1.

Quadro 3: *Ranking* com as 10 subclasses para todas as redes considerando a patente do Quadro 2

Ranking	CNN		LSTM		MLP	
	Subclasse	Probabilidade	Subclasse	Probabilidade	Subclasse	Probabilidade
1	H04W	0,4008	H04W	0,4188	H04W	0,7760
2	H04J	0,2048	H04B	0,2302	H04J	0,1791
3	H04B	0,1616	H04J	0,1716	H04B	0,0149
4	H04L	0,1214	H04L	0,0890	H04L	0,0087
5	H04M	0,0689	H04M	0,0795	C12P	0,0063
6	G01R	0,0166	G01R	0,0080	G01R	0,0049
7	G06F	0,0109	G08B	0,0011	A63F	0,0025
8	G08B	0,0046	G06F	0,0010	C12Q	0,0018
9	E21B	0,0017	H03K	0,0005	H01L	0,0015
10	H03K	0,0012	H04N	0,0001	H04M	0,0012

Fonte: Elaborada pelo autor (2022)

A composição do *ranking* da patente de exemplo, apresentado no Quadro 4, é determinada pela soma das probabilidades até determinada posição do *ranking*. Ou seja, o *ranking* recebe um vetor de  $n$  dimensões, onde  $n$  representa a número de subclasse. A soma das probabilidades do vetor do *ranking* deverá ser igual a 1. Caso  $n=10$ , o resultado da 10ª posição do *ranking* do Quadro 4 (em verde), será a soma das probabilidades das 10 primeiras subclasses de patentes do Quadro 3 (em azul), resultando para as três arquiteturas utilizadas, CNN, LSTM, MLP, em valores de 0,9925, 0,9998, 0,9970, respectivamente.

Quadro 4: *Ranking* da patente exemplo

<i>Ranking</i>	CNN	LSTM	MLP
1	0,4008	0,4188	0,7760
2	0,6056	0,6489	0,9551
3	0,7671	0,8206	0,9700
4	0,8886	0,9095	0,9787
5	0,9575	0,9891	0,9850
6	0,9741	0,9971	0,9900
7	0,9850	0,9982	0,9925
8	0,9896	0,9992	0,9943
9	0,9913	0,9997	0,9958
10	0,9925	0,9998	0,9970

Fonte: Elaborada pelo autor (2022)

Considerando os resultados apresentados nos Quadro 3 e Quadro 4 percebe-se, considerando as subclasses da patente do Quadro 3, H04J e H04W, que as redes CNN e MLP sugeriram as duas classes nas duas primeiras posições na seguinte ordem, H04W e H04J. O mesmo ocorre para a rede neural MLP, mas como uma probabilidade mais elevada para a classe H04W em relação as demais. Para este caso em particular, o resultado pode ser considerado relevante. Por outro lado, a rede neural LSTM sugeriu na primeira posição a classe H04W e na segunda posição a classe H04B que não faz parte da patente em questão. A segunda classe da patente do Quadro 2, H04J, aparece na 3ª posição, mas com uma probabilidade similar a obtida através da outras redes. Para este caso em particular, o resultado pode ser considerado relevante, mas em vários outros as redes neurais testadas tiveram dificuldades em sugerir as subclasses esperadas nas primeiras posições o que pode ser verificado nos resultados agregados apresentados no Quadro 2.

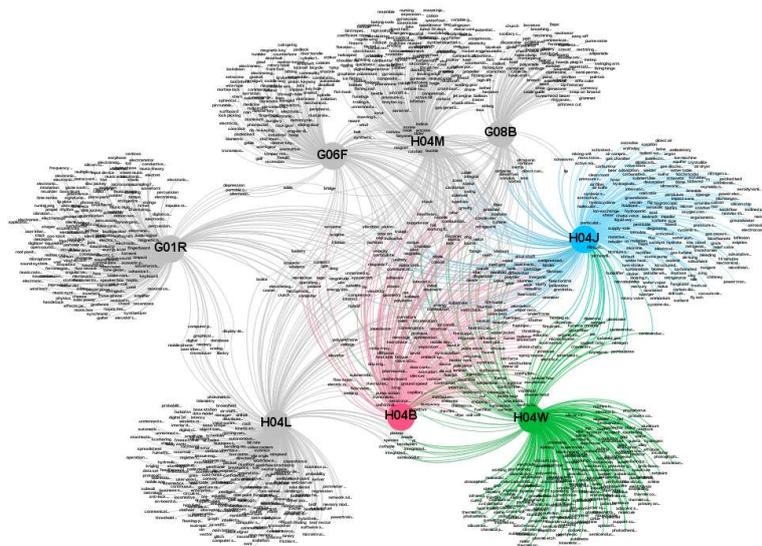
Neste sentido, análises adicionais conectando os resultados dessas redes com o KGs são necessárias para determinar se existe uma arquitetura de aprendizado profundo mais adequada, ou se, para o domínio de análise de patentes, escolher a melhor arquitetura é irrelevante para o modelo proposto. Ou seja, independente da arquitetura, se o modelo, em seu comportamento geral, é capaz de promover resultados que auxiliam na tomada de decisão dos examinadores.

O presente trabalho utiliza também técnicas de PLN na extração de tópicos e relacionamento entre estes e as classes visando a geração de um grafo de conhecimento (KG) que representa o domínio de patentes no cenário de estudo. A ideia geral, consiste na extração dos tópicos de cada classe e geração do KG de modo que este sirva de elemento importante na explicitação do *ranking* de subclasses de patentes facilitando a explicação e visualização dos resultados.

Na Figura 2 é apresentado um grafo de conhecimento gerado pelo modelo conforme o exemplo descrito no Quadro 3 com as 8 (oito) primeiras subclasses de patentes gerados pela rede neural CNN, representadas pelos códigos H04W, H04J, H04B, H04L, H04M, G01R, G06F, G08B, com seus respectivos conceitos.

A representação da Figura 2 enfatiza as subclasses de patentes com maior relevância com base no *ranking* gerado pelo modelo, no exemplo, identificado pelas classes H04W, H04J e H04B sugeridas pela rede neural CNN. O examinador com base na indicação do *ranking* e no grafo de conhecimento, possui elementos que podem auxiliá-lo no processo de tomada de decisão, de tal maneira que a tarefa de classificação no contexto de análise de patentes seja facilitada.

Figura 2: Grafo de Conhecimento com destaque para algumas classes sugeridas



Fonte: Elaborada pelo autor (2022)

#### 4. CONCLUSÃO

O volume dos dados nas bases de patente cresce de maneira expressiva ano a ano. Tais patentes depositadas nos escritórios de patentes necessitam passar por um processo de registro. Com isso, aumenta o número de avaliações de patentes realizadas, o que acarreta uma sobrecarga de trabalho aos examinadores. Uma das tarefas do examinador é a classificação da patente, ou seja, a tarefa de rotular as patentes de acordo com a área tecnológica a que pertencem. Esse processo é realizado de forma manual pelo examinador.

Este trabalho propõe um modelo para auxiliar a análise de patentes, mais especificamente na classificação, por meio de elementos que ajudem na definição da relevância de determinada classe através de *rankings*, assim como explicitem o conhecimento latente presente em bases de patentes. Os resultados parciais do modelo proposto indicam que é possível responder à pergunta de pesquisa. A instanciação do modelo, mesmo que em fase inicial, fornece indícios de suporte à tarefa de classificação realizada por examinadores.

A avaliação do modelo proposto foi efetivada através de um cenário de estudo elaborado com o auxílio do conjunto de dados obtidos na base de patentes do *United States Patent and Trademark Office (USPTO®)*. O conjunto de dados foi preparado para o treinamento em três arquiteturas de redes neurais CNN, LSTM e MLP.

As arquiteturas utilizadas até o momento demonstram serem adequadas para representar a ordenação das classes de patentes. A utilização de *embeddings* de documento juntamente com a codificação das classes demonstrou ser pertinente para a entrada das patentes nas redes neurais. Apesar dos testes iniciais realizados, é possível verificar que a escolha dos métodos e técnicas são relevantes para a instanciação do modelo proposto.

A geração do *ranking*, mesmo que de forma parcial, apresenta um resultado promissor. A estrutura se mostra adequada e, com a realização de ajustes e mais testes espera-se concluir se os resultados atuais podem ser aprimorados ou são reflexo do próprio domínio visto que existem centenas de classes. A implementação do grafo de conhecimento e a vinculação das entidades aos conceitos mapeados em uma base de conhecimento, por exemplo, a *DBpedia®*, é de extrema importância para a explicitação do conhecimento.

Durante a evolução deste trabalho foi possível identificar possíveis melhorias no modelo proposto que, acredita-se irão refletir nos resultados a serem ofertados aos examinadores. Neste sentido, vislumbra-se a possibilidade de testes com outras arquiteturas de redes neurais, como por exemplo, modelos baseados no conceito de *transformers* e *self-attention*. Tais modelos, poderiam viabilizar de maneira contínua, tanto o aprendizado do modelo de classificação quanto a geração dos grafos de conhecimento, aspectos importantes, mas ainda tratados parcialmente neste trabalho.

### AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

### REFERÊNCIAS

- Abdelgawad, L., Kluegl, P., Genc, E., Falkner, S., & Hutter, F. (2020). Optimizing Neural Networks for Patent Classification. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), p. 688–703. [https://doi.org/10.1007/978-3-030-46133-1\\_41](https://doi.org/10.1007/978-3-030-46133-1_41)
- Gomez, J. C., & Moens, M. F. (2014). A survey of automated hierarchical classification of patents. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 8830, 215–249. [https://doi.org/10.1007/978-3-319-12511-4\\_11](https://doi.org/10.1007/978-3-319-12511-4_11)
- Grawe, M. F., Martins, C. A., & Bonfante, A. G. (2017). Automated Patent Classification Using Word Embedding. 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 2017-Decem, 408–411. <https://doi.org/10.1109/ICMLA.2017.0-127>
- Huang, J.-Y., & Tan, K.-W. (2020). An Extension-Based Classification System of Cloud

- Computing Patents. *International Journal of Information Technology & Decision Making*, 19(04), 1149–1172. <https://doi.org/10.1142/S0219622020500248>
- Jafery, W. A. Z. W. C., Omar, M. S. S., Ahmad, N. A., & Ithnin, H. (2019). Classification of Patents according to Industry 4.0 Pillars using Machine Learning Algorithms. 2019 6th International Conference on Research and Innovation in Information Systems (ICRIIS), December-2, 1–6. <https://doi.org/10.1109/ICRIIS48246.2019.9073669>
- Li, S., Hu, J., Cui, Y., & Hu, J. (2018). DeepPatent: patent classification with convolutional neural networks and word embedding. *Scientometrics*, 117(2), 721–744. <https://doi.org/10.1007/s11192-018-2905-5>
- Lu, H., Liu, X., Yin, Y., & Chen, Z. (2019). A Patent Text Classification Model Based on Multivariate Neural Network Fusion. 6th International Conference on Soft Computing & Machine Intelligence (ISCMI), 61–65. <https://doi.org/10.1109/ISCMI47871.2019.9004335>
- Min, H. (2021). Power patent classification method based on deep neural network. *Journal of Physics: Conference Series*, 1848(1), 012048. <https://doi.org/10.1088/1742-6596/1848/1/012048>
- Risch, J., & Krestel, R. (2019). Domain-specific word embeddings for patent classification. *Data Technologies and Applications*, 53(1), 108–122. <https://doi.org/10.1108/DTA-01-2019-0002>
- Roudsari, A. H., Afshar, J., Lee, C. C., & Lee, W. (2020). Multi-label Patent Classification using Attention-Aware Deep Learning Model. 2020 IEEE International Conference on Big Data and Smart Computing (BigComp), 558–559. <https://doi.org/10.1109/BigComp48618.2020.000-2>
- Sofean, M. (2021). Deep learning based pipeline with multichannel inputs for patent classification. *World Patent Information*, 66, 102060. <https://doi.org/10.1016/J.WPI.2021.102060>
- Trappey, A., Trappey, C. V., & Hsieh, A. (2021). An intelligent patent recommender

adopting machine learning approach for natural language processing: A case study for smart machinery technology mining. *Technological Forecasting and Social Change*, 164, 120511. <https://doi.org/10.1016/j.techfore.2020.120511>

WIPO. (2021). *World Intellectual Property Indicators 2021*. (p. 232). p. 232. <https://doi.org/10.34667/tind.44461>

WIPO. (2022). *International Patent Classification (IPC)* (p. 8). p. 8. CH-1211 Geneva 20, Switzerland: WIPO.

Yun, J., & Geum, Y. (2020). Automated classification of patents: A topic modeling approach. *Computers & Industrial Engineering*, 147, 106636. <https://doi.org/10.1016/j.cie.2020.106636>

Zhu, H., He, C., Fang, Y., Ge, B., Xing, M., & Xiao, W. (2020). Patent Automatic Classification Based on Symmetric Hierarchical Convolution Neural Network. *Symmetry*, 12(2), 186. <https://doi.org/10.3390/sym12020186>