

# Um Método de Inteligência Artificial para o Aprendizado Significativo Aplicando Matrizes de Markov

## Autores

Bruno Zolotareff dos Santos<sup>1</sup>

Leandro Reginaldo<sup>2</sup>

## Resumo

O uso de recursos digitais está se tornando cada vez mais comum no processo de aprendizagem, especialmente as ferramentas generativas que facilitam a busca por informações. Esse tema tem sido amplamente discutido por profissionais da educação. Uma das principais dificuldades enfrentadas é a supervisão dos estudantes de maneira significativa, orientando-os dentro de um planejamento que ajude a preencher as lacunas de conhecimento e a completar seu entendimento sobre o objeto de estudo. A implementação de tecnologias inovadoras nas plataformas de aprendizagem traz desafios, especialmente no que diz respeito à supervisão e ao desenvolvimento das capacidades cognitivas dos estudantes. É necessário que, dentro de um grupo de estudo, os estudantes consigam aprimorar seu autoconhecimento de forma colaborativa para organizar e compartilhar ideias relacionadas aos estudos, supervisionado por uma Inteligência Artificial. Essa IA recomenda um conjunto de metadados relacionados ao conhecimento coletivo gerado na plataforma desenvolvida, denominada e-Folks. Além disso, cada estudante terá acesso a um mapa mental, permitindo uma supervisão direcionada por meio de algoritmos de *Machine Learning* e se necessário, a intervenção do professor na plataforma de ensino.

**Palavras-chave:** Aprendizagem. Inteligência artificial. Conhecimento. Machine learning.

*An Artificial Intelligence Method for Meaningful Learning by Applying Markov Matrices*

## Abstract

*The use of digital resources is becoming increasingly common in the learning process, particularly generative tools that facilitate information retrieval. This topic has been extensively discussed among education professionals. One of the primary challenges faced is the meaningful supervision of students, guiding them within a framework that helps fill knowledge gaps and enhances their understanding of the subject matter. The implementation of innovative technologies in learning platforms presents challenges, especially regarding supervision and the development of students' cognitive abilities. It is essential that, within a study group, students can collaboratively enhance their self-awareness to organize and share ideas related to their studies, under the supervision of an artificial intelligence system. This AI recommends a set of metadata related to the collective knowledge generated on the developed platform, known as e-Folks. Furthermore, each student will have access to a mind map, allowing for targeted supervision through Machine Learning algorithms and, if necessary, intervention by the instructor within the educational platform.*

**Keywords:** Learning. Artificial intelligence. Knowledge. Machine learning.

## INTRODUÇÃO

As ferramentas digitais se tornam cada vez mais presente no cotidiano de estudantes de diversas áreas do conhecimento e profissionais envolvidos na área da educação. Desde o advento da Web semântica onde é gerado o conhecimento coletivo que contribui com suas

<sup>1</sup> Doutorado em Engenharia Elétrica pela Universidade de São Paulo – USP e docente na Faculdade de Tecnologia do Estado de São Paulo – Fatec Mauá /SP. Orcid: 0000-0001-9233-4312

<sup>2</sup> Especialização em Análise de Dados pelo Centro Universitário União das Américas Descomplica e docente no Centro Estadual de Educação Tecnológica Paula Souza. Orcid: 0009-0001-0283-7248

informações no uso de ferramentas de recomendação auxiliadas por sistemas de *Machine Learning* (CORDEIRO, 2020).

A utilização de algoritmos supervisionados no uso do aprendizado significativo é um dos caminhos utilizados para mensurar o conhecimento do aprendiz em tempo real. Porém, um dos poucos meios que mede a capacidade cognitiva do aprendiz em relação ao objeto de estudo e consegue identificar as lacunas de conhecimento faltantes para preencher as informações faltantes para completar o saber (CONRAD, 2019).

Portanto, não há uma maneira única de avaliar e mensurar o conhecimento considerando apenas um caminho para a aprendizagem. Construir ideias usando diferentes meios de tecnologia sem considerar o que o aprendiz já sabe pode ser visto como um erro em qualquer processo de aprendizagem (AGRA, 2019).

Alguns sistemas baseados em descoberta de conhecimento são aplicados a grandes quantidades de dados na Web e adicionalmente utilizados em redes sociais. Os dados identificados, principalmente em sistemas colaborativos, como redes sociais, passam por um processo dinâmico, alterando a interpretação dos metadados devido à interação do usuário dentro de um processo contínuo de aprendizagem colaborativa.

É preciso adotar um novo conceito que leve em conta não apenas o uso de metadados para organizar e recuperar informações, mas também a qualidade dos metadados empregados pelos alunos no processo de aprendizagem. Para definir quais metadados utilizar com base na Inteligência Coletiva gerada em um sistema colaborativo, é fundamental aplicar métricas cognitivas que classifiquem os metadados conforme seu nível de conhecimento (ELAHI et al., 2016).

A busca por descobrir o conhecimento e o que fazer e onde aplicar esse conhecimento é um desafio que envolve um conjunto de soluções e tecnologias diferenciadas, tornando o conhecimento dos dados o principal valor. Sendo um diferencial no processo de aprendizagem o uso de tecnologias para preencher lacunas de conhecimento que o aprendiz necessita para atingir seu objetivo, que é dominar o conhecimento do objeto de estudo.

A busca por entender o conhecimento, saber o que fazer com ele e onde aplicá-lo é um desafio que envolve diversas soluções e tecnologias, colocando o domínio dos dados como o principal valor. No processo de aprendizagem, o uso de tecnologias torna-se um diferencial ao preencher as lacunas de conhecimento que o aprendiz precisa superar para alcançar seu objetivo: dominar o objeto de estudo.

A evolução dos sistemas analíticos traz fatores de grande relevância em uma era marcada pelo uso da computação cognitiva, impulsionada por meios colaborativos. Nessa

abordagem, o conhecimento é enriquecido com base na aprendizagem humana, tornando-se uma ferramenta poderosa para apoiar o processo de aprendizado (LIMA, 2018).

A capacidade dos sistemas de reconhecer o nível cognitivo em uma rede colaborativa pode alavancar metadados porque envolve um esforço coletivo de muitos usuários em sua interação com sistemas de classificação livres de metadados (VIANA, 2019).

O vasto volume de dados e a geração de conhecimento em sistemas Web podem ser grandes aliados no processo de aprendizagem supervisionada. No entanto, para que esses dados sejam aproveitados adequadamente, técnicas de Mineração de Dados são aplicadas na sumarização, facilitando a descoberta de conhecimento e, sobretudo, na classificação dos dados em sistemas colaborativos, contribuindo para o processo de aprendizagem contínua (AHMED, 2019).

O objetivo da pesquisa é fornecer um método de classificação de metadados no nível de conhecimento para serem aplicados em um sistema de recomendação no processo de aprendizagem. Isso visa oferecer metadados que representem o valor agregado de forma colaborativa, especialmente em sistemas que utilizam processos de marcação. Tal abordagem permite organizar a aprendizagem por meio de termos (palavras-chave), facilitando a estruturação de ideias através da construção de um mapa mental, utilizando o conhecimento coletivo com o apoio de ferramentas tecnológicas.

Dessa forma, busca-se utilizar métricas cognitivas que possam mensurar o conhecimento gerado colaborativamente em uma matriz de classificação, facilitando a compreensão e a avaliação da relevância do conjunto de metadados sugeridos pelo sistema de recomendação.

## **1.1 Objetivo**

Aplicar o método da Cognomia com as matrizes de Markov para classificação de metadados e sugestão de um grupo de metadados em nível de conhecimento para ser utilizado no processo de aprendizagem do estudante possibilitando a construção de um mapa mental que representa o preenchimento das lacunas faltantes de conhecimento para chegar ao saber referente ao objeto de estudo, possibilitando ser supervisionado em relação ao desempenho durante o período de aprendizagem.

## **2 REFERENCIAL TEÓRICO**

A organização de conteúdo em plataformas de aprendizagem baseia-se em padrões de metadados que servem como fundamento para estruturar os dados disponíveis, como apontado em diversos estudos (DAGGER, 2007; KASIM, 2016; TILLAEV, 2023). No

entanto, dados não estruturados nessas plataformas também utilizam a folksonomia como um subsistema, permitindo que os alunos pratiquem livremente a marcação, contornando assim o desafio de encontrar e organizar os dados de maneira lógica e personalizada para cada usuário (PETER, 2011).

O uso de sistemas virtuais para organização, recuperação de informações e aprendizado tem suas raízes em princípios de metadados originalmente empregados em projetos militares, posteriormente adaptados para software voltado à busca de materiais científicos, facilitando a organização prática de estudos relacionados ao tema (WILSON, 2015).

Além das plataformas de aprendizagem e da marcação para organizar e recuperar informações, outras estratégias são empregadas para estruturar metadados, como o uso de redes cognitivas em diversas áreas do conhecimento e em pesquisas (AL-JARF, 2022; TANTAM, 2006).

A organização de metadados por meio de comunicação colaborativa não é novidade. Desde a implementação de sistemas de aprendizagem online e redes sociais, a marcação tem sido amplamente disponível. O problema, no entanto, está na limitação dos sistemas de recomendação que utilizam essas marcações. Muitas vezes, os metadados não representam conhecimento de qualidade, e sua reutilização pode gerar problemas de engajamento nas redes colaborativas.

Em relação aos metadados, alguns pesquisadores aplicam técnicas de Mineração de Dados para aprimorar a qualidade dos dados gerados pela prática de marcação em diferentes tipos de aplicações (CHELMIS; PRASANN, 2011; CORLEY, 2010; PIERCE, 2008). O uso de sistemas colaborativos na web, com subsistemas de marcação, é amplamente difundido, e algumas análises são realizadas com técnicas de *Machine Learning*. Além disso, mapas mentais são usados como uma maneira de estruturar o conhecimento em redes cognitivas.

Contudo, a proposta desta pesquisa é melhorar a qualidade dos metadados oferecidos nos sistemas de recomendação para o aprendizado, de forma que o aprendiz possa visualizar e identificar claramente o nível de conhecimento associado a cada marcação.

### 3 MÉTODO

Para aplicação do método proposto da Cognomia com as matrizes de Markov é necessário passar por algumas fases de preparação das amostras dos metadados; esse processo do KDD (*Knowledge Discovery in Databases*) conhecido como *Data Mining*, e durante a fase desse processo é aplicado o algoritmo supervisionado proposto para encontrar padrões e serem aplicados utilizando o *Machine Learning*, conforme ilustrado na Figura 1:

- *Seleção*: Após a extração dos metadados relacionado aos posts sobre temas de Inteligência Artificial, cerca de vinte e três mil e quinhentos e quatro dos tweets da rede social X (antes Twitter), realiza-se a separação desses dados para formar uma amostra.
- *Pré-processamento*: A amostra é carregada em uma instância do banco de dados para análise. Durante essa fase, são aplicados filtros para remoção de ruídos, e os metadados são organizados em um formato de *Bag of Words* (BOW).
- *Transformação*: Nessa etapa, algumas regras de filtragem e categorização são aplicadas. Os metadados são contados para verificar sua frequência, utilizando a técnica de *Term Frequency - Inverse Document Frequency* (TF-IDF).
- *Mineração de Dados*: Com os metadados preparados na fase de transformação, as regras de separação, contagem e aplicação da folksonomia é aplicada para separação dos metadados em grupos prontos para serem avaliados no processo de *Machine Learning*.
- *Padrões*: Com os metadados já categorizados e selecionados é aplicado a matriz de Markov e as métricas cognitivas e as expressões que equilibram os valores obtido no cálculo. Conforme as etapas descritas e ilustradas na Figura 1:
  - *Pré-processamento*: Os dados categorizados são organizados nas amostras conforme a necessidade da aplicação.
  - *Seleção do algoritmo*: É utilizado um algoritmo supervisionado com a matriz de Markov e as métricas cognitivas e as expressões que equilibram os valores obtido no cálculo.
  - *Treinamento*: O algoritmo supervisionado aplica as regras estabelecidas para obtenção dos resultados calculados com a matriz de Markov e os metadados são classificados utilizando regressão e classificação.
  - *Testes e avaliação do modelo*: O modelo utilizado baseado nas matrizes de Markov em um método denominado Cognomia é uma alternativa para utilização do coeficiente de Pearson que é outro modelo que é aplicado em algoritmos.
- *Avaliação*: Após a categorização dos metadados, o algoritmo NCC realiza a avaliação com base nos índices gerados pelas métricas em sua lógica, rotulando os resultados de acordo com sua magnitude. Para isso, aplica as regras de avaliação de Jacob Cohen, uma prática conhecida como Reconhecimento de Entidade Nomeada (NER).

**Figura 1:** Processo de descoberta de conhecimento



Fonte: Adaptado de Fayyad (1996)

Para a aplicação do KDD, é necessário considerar diversas etapas do algoritmo NCC que envolvem métricas cognitivas no processo de classificação, o funcionamento do algoritmo e a descrição das métricas são detalhados nas próximas seções.

Os dados passaram por uma análise supervisionada de *Machine Learning*, onde a classe de comparação era previamente conhecida. Este estudo buscou aprofundar o entendimento popular sobre a palavra-chave: Inteligência Artificial ou IA; utilizando o conhecimento coletivo como uma ferramenta para enriquecer o aprendizado ao longo do processo contínuo.

O conjunto de metadados serviu como a base para a memória gerada pela Inteligência Coletiva. Isso possibilitou a comparação do conhecimento dos estudantes durante a seleção de informações com o conhecimento coletivo, permitindo a classificação dos metadados da busca em diferentes níveis de conhecimento.

### 3.1 Protótipo para aplicação da metodologia

O protótipo desenvolvido chamado e-Folks aplica a prática de marcação usando o sistema de recomendação de metadados na forma de *tags* para que o aprendiz possa utilizá-lo durante o processo de estudo do objeto. Para iniciar o estudo colaborativo, o orientador divulga o objeto de estudo para os estudantes que pertencem ao mesmo grupo de estudo, o que é ilustrado na Figura 2.

**Figure 2:** e-Folks screen for learners to post their items



Fonte: Os autores

Após o primeiro post no sistema de estudo colaborativo, os demais estudantes que utilizam o sistema passam a contribuir com dados importantes no processo de aprendizagem, adicionando conteúdo aos seus posts e principalmente indexando *tags* relacionadas ao assunto. Na Figura 3 é possível observar que há mais duas posições além do orientador contribuindo para o aprendizado contínuo de forma colaborativa.

**Figure 3:** e-Folks tela com postagens já realizadas

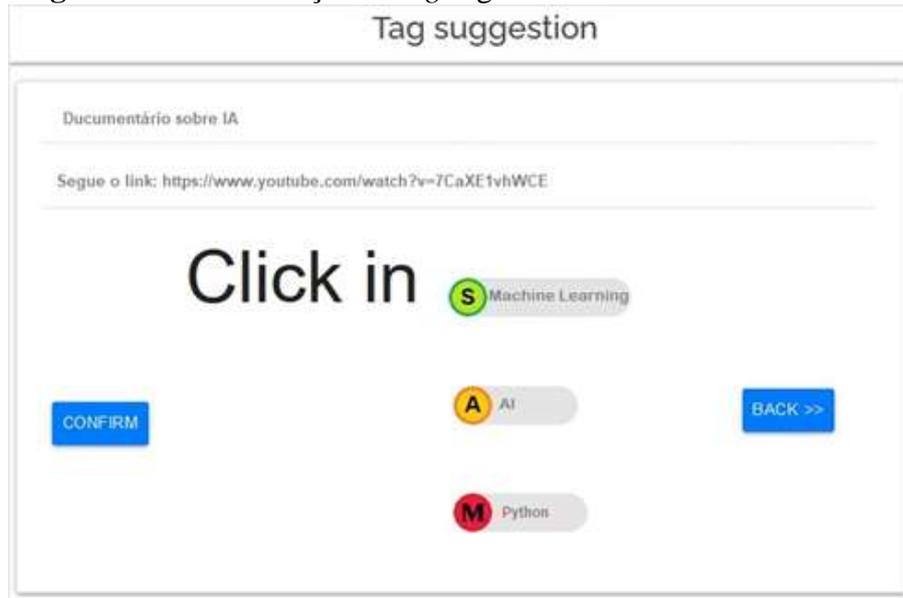


Fonte: Os autores

A interação dos estudantes com a plataforma de aprendizagem colaborativa gera metadados que são as *tags* indexadas nas postagens, possibilitando a construção de um mapa mental para cada aprendiz, onde suas *tags* serão utilizadas como forma de organizar o conteúdo estudado e as *tags* dos demais estudantes que podem ajudar a construir conhecimento.

Este protótipo foi utilizado com um grupo anônimo de alunos para verificar a metodologia de aprendizagem proposta utilizando metadados no nível do conhecimento em um processo de aprendizagem contínua, os resultados do experimento estão na seção de aplicação do experimento. Para o processo de escolha das *tags*, a ferramenta e-Folks utiliza seu sistema de recomendação de metadados ilustrado na Figura 4.

**Figura 4:** Recomendação de *tags* agradao o nível de conhecimento



Fonte: Os autores

### 3.2 Métricas para Classificação dos Metadados Extraídos do Sistema de Recomendação

O método utilizado neste trabalho para classificar os metadados é fundamentado nas métricas de linearidade do método de Markov e na interpretação de magnitude de Jacob Cohen, considerando as faixas de valores de -1,0 a 1,0, que servem como referência para os resultados desta pesquisa (MCHUGH, 2012).

A faixa de -1,0 a 1,0 utilizada é baseada nas margens dos cálculos de Markov. A interpretação dos valores que pertencem a essa escala serve como referência de magnitude segundo Jacob Cohen, que define rótulos para interpretar o nível de ajuste dos dados aos intervalos, categorizando-os como: ‘alto’, ‘médio’ e ‘baixo’. A interpretação de Jacob Cohen dos resultados de correlação como uma forma de entender a magnitude é apresentada nos seguintes intervalos (CORRELL, 2019; KRAFT, 2019; MCHUGH, 2012):

- Valores  $\leq 0,0$ : indicando nenhuma concordância
- Intervalo de 0,0 a 0,20: sem nível
- Intervalo de 0,21 a 0,59: moderado
- Intervalo de 0,60 a 0,90: forte

Os valores estabelecidos nos intervalos e os rótulos que identificam o status do significado da métrica foram definidos por Jacob Cohen. Esses critérios são utilizados nesta pesquisa e adaptados conforme as regras estabelecidas para os níveis de classificação de metadados, conforme adaptações realizadas por outros pesquisadores que utilizam cálculos de correlação (KOTTNER, 2011; VANBELLE, 2016).

### 3.2.1 Parâmetros das Métricas Aplicadas

Os valores utilizados nos parâmetros são extraídos da frequência dos termos utilizados nos metadados, que são compartilhados no sistema colaborativo. Esses valores, obtidos a partir do processo de marcação, representam o conhecimento coletivo gerado no sistema e formam a base dos valores utilizados nas expressões estabelecidas nesta pesquisa.

Para calcular as métricas MCC (Monitoramento do Conhecimento Coletivo) e DMC (Desvio no Monitoramento do Conhecimento), foram necessários alguns atributos baseados em uma escala de correlação baseada nos resultados da matriz de Markov, que varia entre um intervalo de -1,0 e 1,0. Esses atributos são: FT, M1, M2, M3, M4 e FC da Tabela 1, onde cada variável serve apenas como um índice, com valores atribuídos de acordo com a regra estabelecida pelo algoritmo de recomendação.

**Tabela 1:** Significado dos parâmetros

Sigla	Descrição
FT	Frequência do termo de metadados escolhido no sistema.
M1	Verificação se o termo de metadados escolhido está entre as três primeiras posições do vetor.
M2	Se o termo de metadados escolhido pertence à primeira posição do vetor.
M3	Se o termo de metadados escolhido está entre a segunda e a terceira posições.
M4	Se o termo de metadados escolhido está entre as três primeiras posições do vetor.
FC	Frequência do conjunto de metadados ordenado.

Fonte: Os autores

Esses parâmetros são fundamentais para calcular as métricas MCC e DMC, permitindo uma análise mais precisa do conhecimento coletivo e da utilização de metadados no sistema colaborativo.

Para aplicar a metodologia desenvolvida, são utilizadas duas expressões (1) e (2) para calcular o MCC (Monitoramento do Conhecimento Coletivo) e o DMC (Desvio no Monitoramento do Conhecimento). A expressão NCC avalia o nível de concordância, resultando na soma das expressões MCC e DMC, variando assim de -1,0 a +1,0. Esse intervalo permite obter um valor correlacionado dentro do grupo classificado pelo algoritmo proposto neste trabalho.

É necessário aplicar um modelo de Markov que geralmente lida com estados e transições, focando nas probabilidades de mover de um estado para outro. Ao utilizar a matriz do modelo de Markov, a expressão adaptada para o uso do algoritmo supervisionado aplicado ao *Machine Learning* é representada assim:

$$M_{\text{Markov}} = \frac{E[X \cdot Y]}{E[N] \cdot E[Y^2]}$$

- Onde:
  - $E[X \cdot Y]$ : Isso representa o valor esperado do produto de duas variáveis aleatórias X e Y que são estados no processo de Markov.
  - $E[N]$ : Isso representa o número esperado de transições.
  - $E[Y^2]$ : Isso representa o valor esperado do quadrado do estado Y.
- Entendendo o Contexto:

Nesta formulação baseada em Markov,  $M_{\text{Markov}}$  mede a relação entre os resultados esperados de dois estados, considerando o número de transições.

- a) **Probabilidades de Transição:** Se uma matriz de probabilidades de transição  $P$ , poderá derivar  $E[X \cdot Y]$  a partir dela, multiplicando as probabilidades relevantes.
- b) **Normalização:** O denominador  $E[N] \cdot E[Y^2]$  serve para normalizar o valor, garantindo que ele reflita a distribuição dos estados ao longo das transições.

Com o valor obtido de  $M$ , é possível obter uma estimativa de correlação, porém, é necessário considerar alguns aspectos por se tratar de um sistema colaborativo.

Para mitigar qualquer interferência no processo de classificação de metadados, é necessário utilizar uma expressão de pesos e medidas para mitigar interferências que ocorrem no processo de comunicação, principalmente por se tratar de um ambiente colaborativo que pode causar interferência no processo de marcação. Para mitigar qualquer interferência no processo de qualificação de metadados, é realizado o seguinte cálculo da expressão:

$$MCC = (M * (FT + [(M1 + M2) / 2 * -0,50] + [(M3 + M4) * -1,00]) / FC)$$

Na expressão (2) o cálculo é utilizado para mensurar o desvio de acurácia considerando uma aproximação ao valor ideal estabelecido. As mesmas variáveis são utilizadas como base para serem aplicadas a esta expressão.

$$DMC = ((M1 * 0,50) + (M2 * -0,50) + (M3 * 1,00) + (M4 * -1,00)) / FC$$

Para aplicar estas métricas dentro de um sistema como o e-Folks, foi necessário criar um algoritmo genérico ilustrado na Figura 2, capaz de executar estas funções, desde ordenar aplicando folksonomia, e sugerir *tags* no nível do conhecimento.

Os valores atribuídos às variáveis M1, M2, M3 e M4 dependem da comparação entre os metadados escolhidos pelo aprendiz com os metadados das quatro primeiras posições gerados pela folksonomia do sistema representado na Tabela 2.

**Tabela 2:** Parâmetros utilizados nas expressões MCC e DMC

Vetor	M1	M2	M3	M4
Posição (1)	1,00	1,00	1,00	0,00
Posição (2)	0,50	0,50	0,50	0,00
Posição (3)	0,25	0,25	0,25	0,00
Posição (4)	-1,00	-1,00	-1,00	0,00

Fonte: Os autores

A soma dos valores de MCC e DMC tem como objetivo regular a estimativa e o desvio que o usuário tem durante o ato de escolher a resposta, no caso, os metadados. Essa soma resulta no NCC, que é a principal métrica que representa o nível de conhecimento dos metadados segundo a proposta.

$$NCC = MCC + DMC$$

O valor do NCC está relacionado ao conhecimento adicionado aos metadados escolhidos pelo usuário, e possível não concordância com os metadados mais indicados pelo conhecimento coletivo, considerando a comparação com os metadados melhor posicionados pela frequência. Com o valor do NCC é baseado na interpretação de Jacob Cohen interpretada na Tabela 3 (KRAFT, 2019):

**Tabela 3:** Interpretação dos valores de NCC

Classificação da escala NCC	
<b>Menor que 0,29</b>	Baixo nível de conhecimento
<b>0,29 a &lt; 0,49</b>	Nível médio de conhecimento
<b>Maior que 0,50</b>	Alto nível de conhecimento

Fonte: Os autores

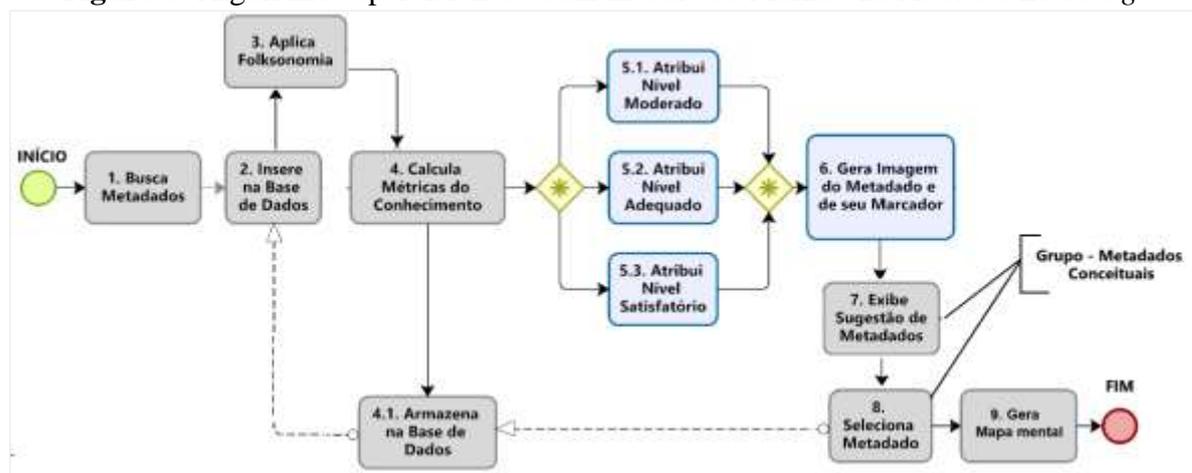
### 3.3 Aplicadas no algoritmo de classificação

O fluxograma contido na Figura 5 representa o algoritmo proposto, com suas fases descritas a seguir:

- *Início:* Os metadados são gerados pelos alunos na plataforma colaborativa direcionada ao objeto de estudo.
- *Inserir na Base de Dados:* Uma amostra de um conjunto de metadados é carregado na base de dados utilizada como base de conhecimento inicial.
- *Aplica a Folksonomia:* É feita uma comparação entre o conhecimento do aluno e o conhecimento coletivo gerado no sistema de recomendação de aprendizagem.

- *Calcula Métricas do Conhecimento*: O termo de entrada é comparado com o conhecimento coletivo gerado pelos metadados compartilhados no modo colaborativo.
- *Atribui Nível Moderado, Adequado e Satisfatório*: Após a análise do termo de comparação realizado pelas métricas e pelo modelo de Markov é atribuído um nível de conhecimento relacionado ao metadados sugerido para o usuário.
- *Gera Imagem do Metadado e se seu Marcador*: De acordo com o nível de conhecimento do metadado é gerado um símbolo que é agregado as *tags* que são recomendados.
- *Exibe Sugestão de Tags*: Após a verificação e aplicação das métricas, o sistema sugere três metadados no nível de conhecimento para serem indexados na forma de *tags*.
- *Seleciona Metadados*: O estudante seleciona os metadados em forma de *tags* para indexar o conteúdo em suas postagens relacionado ao objeto de estudo.
- *Mapa Mental*: Quando o estudante recebe sugestões de *tags* do sistema, é gerado um mapa mental que representa os metadados utilizados no processo de marcação no período de aprendizagem, que é contínuo.
- *Avaliação*: O mapa mental pode ser avaliado por um consultor especialista que pode sugerir alguns metadados que complementem seu conhecimento.
- *Fim*: Uma vez que os metadados são adicionados ao mapa mental, o aluno conclui o processo e pode atualizar cada interação com o sistema.

**Figura 5:** Algoritmo supervisionado com modelo de Markov no *Machine Learning*



Fonte: Os autores

#### 4 RESULTADOS E DISCUSSÃO

Ao analisar o resultado dos metadados gerados pelos dois estudantes voluntários sem identificação, sendo um período de seis meses que utilizaram a plataforma como meio de estudos em relação a disciplina relacionado com Inteligência Artificial.

O objetivo é que o estudante consiga preencher as lacunas de conhecimento que ainda precisam ser preenchidas, utilizando gatilhos mentais com o auxílio de metadados, não precisando estudar o conteúdo, apenas completando o conhecimento para atingir o objetivo que é a finalidade da aprendizagem significativa (AGRA, 2019).

Atingir os objetivos no processo de estudo utilizando uma ferramenta colaborativa pode potencializar a aprendizagem, melhorando a compreensão dentro de um contexto direcionado ao objeto de estudo, como foi feito no experimento com metadados.

É possível notar pela análise que os metadados utilizados pelos estudantes foram sugeridos pelo sistema de recomendação, chegando a um resultado satisfatório para um experimento inicial com a ferramenta e-Folks que aplica as métricas sugeridas.

Os metadados utilizados na instância que é carregada em um vetor foram gerados pelos usuários e alguns termos foram inseridos pelos moderadores do e-Folks como forma de direcionar o aprendizado do algoritmo utilizado para o estudo relacionado ao termo Inteligência Artificial.

Mesmo sendo um experimento realizado em cento e oitenta dias e utilizando apenas dois estudantes para investigar o experimento, o trabalho foi válido por se tratar de dados reais gerados por usuários do sistema e-Folks. Os metadados utilizados pelos dois estudantes e os metadados sugeridos pelo sistema de recomendação estão ilustrados na Tabela 4.

**Tabela 4:** Os metadados utilizados pelos estudantes e pela recomendação

Collaborative	Aprendiz 1	Aprendiz 2
Inteligência Artificial	Inteligência Artificial	Inteligência Artificial
Aprendizado de máquina	Aprendizado de máquina	Estatística
Algoritmo	Algoritmo	Aprendizado de máquina
Weka	Estatística	Weka
Metadado	Collab	Watson
Watson	Weka	Metadado
Estatística	Metadado	Algoritmo
Collab	Python	Collab
Python	Algoritmo	Python

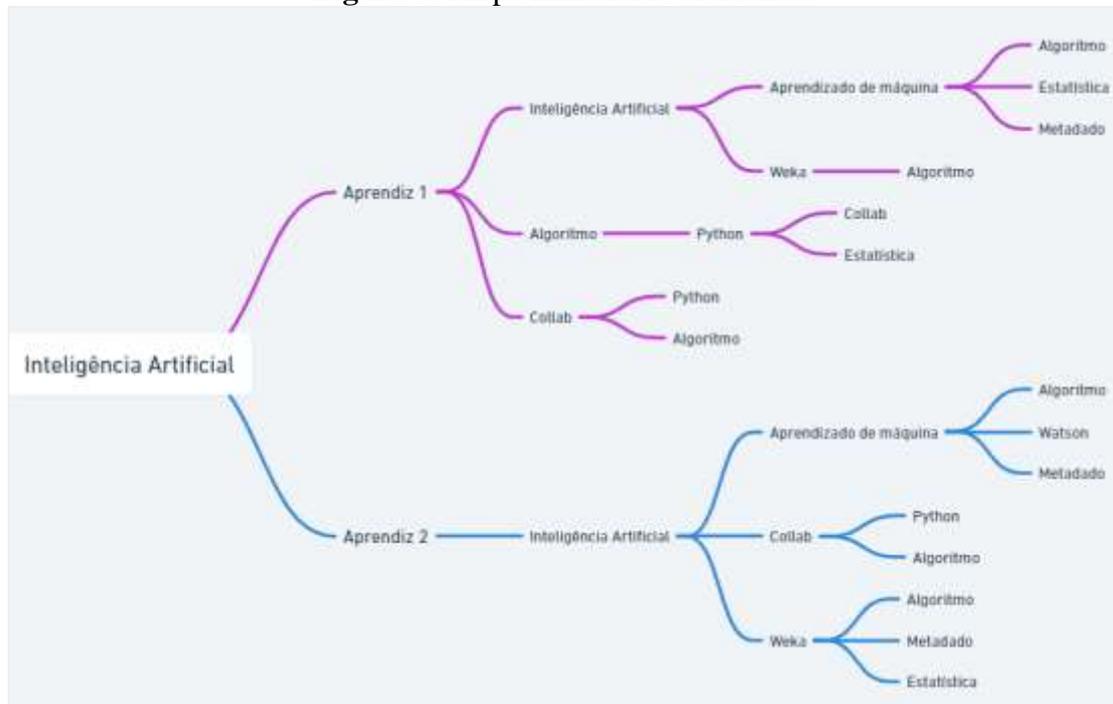
Fonte: Os autores

Embora a experiência tenha sido realizada com apenas dois estudantes em um curto período, é importante ressaltar que este é um modelo de aprendizagem supervisionada.

Não são necessários muitos estudantes para avaliar o funcionamento do sistema; assim, pode-se considerar que a performance alcançada é adequada para o objetivo de promover o aprendizado por meio de recursos tecnológicos, com a interação colaborativa entre os usuários.

Com esse experimento foi possível gerar o mapa mental dos estudantes trazendo uma nova visão do aprendizado significativo com auxílio de ferramentas e Inteligência Artificial que está representada na Figura 6.

**Figura 6:** Mapa mental dos estudantes



Fonte: Os autores

O uso de metadados classificados de acordo com níveis de conhecimento é uma característica distintiva que não é comumente encontrada em outras ferramentas de aprendizagem. Os resultados da comparação entre os estudantes e os metadados sugeridos pelo sistema de recomendação revelam uma similaridade significativa na linearidade dos metadados escolhidos, evidenciando a eficácia do sistema de recomendação implementado.

## CONSIDERAÇÕES FINAIS

O estudo de sistemas de aprendizagem colaborativa é essencial para a construção do conhecimento, especialmente quando se utilizam ferramentas colaborativas que oferecem recursos valiosos. Ferramentas como o e-Folks, projetadas para esse propósito, exploram áreas pouco abordadas, como o uso da Inteligência Coletiva para promover a aprendizagem significativa em redes sociais.

Embora a importância da Inteligência Coletiva e a aplicação de ferramentas de Inteligência Artificial para aprimorar suas capacidades sejam amplamente discutidas, ainda há uma escassez de estudos focados na qualidade dos metadados em sistemas de aprendizagem colaborativa.

Os metadados, que atuam como palavras-chave, são fundamentais para ativar a cognição e facilitar o entendimento do objeto de estudo, além de representar o conhecimento humano por meio da linguagem natural. Com a aplicação de técnicas de Mineração de Dados, é possível resumir dados de maneira eficaz, aprimorando a seleção de metadados no contexto do sistema de recomendação e-Folks.

Este estudo forneceu dados significativos, ainda que não totalmente conclusivos, sobre a eficácia do uso de sistemas colaborativos que implementam um sistema de *tags* no nível do conhecimento. No entanto, a experiência com os estudantes utilizando a ferramenta e-Folks oferece novas perspectivas sobre o uso do algoritmo NCC e suas métricas cognitivas, que geraram metadados suficientes para uma análise comparativa entre os usuários e o sistema de recomendação.

### **Trabalhos futuros**

A ferramenta e-Folks foi desenvolvida para aplicar o algoritmo NCC em um método de descoberta de conhecimento, utilizando técnicas de *Machine Learning*. Essa ferramenta possui potencial para ser aprimorada e implantada em um servidor permanente, permitindo sua aplicação em grupos maiores de estudantes.

### **REFERÊNCIAS**

- AGRA, Glenda et al. Análise do conceito de Aprendizagem Significativa à luz da Teoria de Ausubel. **Revista Brasileira de Enfermagem**, v. 72, p. 248-255, 2019.
- AHMED, Mohiuddin. Data summarization: a survey. **Knowledge and Information Systems**, v. 58, n. 2, p. 249-273, 2019.
- AL-JARF, Reima. Online vocabulary tasks for engaging and motivating EFL college students in distance learning during the pandemic and post-pandemic. **International Journal of English Language Studies (IJELS)**, v. 4, n. 1, p. 14-24, 2022.
- CHELMIS, Charalampos; PRASANNA, Viktor K. Social networking analysis: A state of the art and the effect of semantics. **In: 2011 IEEE Third International Conference on Privacy, Security, Risk and Trust and 2011 IEEE Third International Conference on Social Computing**. IEEE, p. 531-536, 2011.
- CONRAD, Dianne; OPENO, Jason. Estratégias de avaliação para a aprendizagem online. São Paulo: **Artesanato Educacional**, 2019.
- CORDEIRO, Karolina Maria de Araújo. O impacto da pandemia na educação: a utilização da tecnologia como ferramenta de ensino. **IDAAM**, C3, v. 87, p. C3, 2020.
- CORLEY, Courtney D. et al. Text and structural data mining of influenza mentions in web and social media. **International journal of environmental research and public health**, v. 7, n. 2, p. 596-615, 2010.

CORRELL, Joshua et al. Avoid Cohen's 'small', 'medium', and 'large' for power analysis. **Trends in cognitive sciences**, v. 24, n. 3, p. 200-207, 2020.

DAGGER, Declan et al. Service-oriented e-learning platforms: From monolithic systems to flexible services. **IEEE internet computing**, v. 11, n. 3, p. 28-35, 2007.

ELAHI, Mehdi; RICCI, Francesco; RUBENS, Neil. A survey of active learning in collaborative filtering recommender systems. **Computer Science Review**, v. 20, p. 29-50, 2016.

FAYYAD, Usama, PIATETSKY-SHAPIRO, Gregory e SMYTH, Padhraic. From Data Mining to Knowledge discovery. American Association for Artificial Intelligence. 1996.

KASIM, Nurul Nadirah Mohd; KHALID, Fariza. Choosing the right learning management system (LMS) for the higher education institution context: A systematic review. **International Journal of Emerging Technologies in Learning**, v. 11, n. 6, 2016.

KOTTNER, Jan et al. Guidelines for reporting reliability and agreement studies (GRRAS) were proposed. **International journal of nursing studies**, v. 48, n. 6, p. 661-671, 2011.

KRAFT, Matthew A. Interpreting effect sizes of education interventions. **Educational Researcher**, v. 49, n. 4, p. 241-253, 2020.

LIMA, Edivania Barros et al. HQ'S VIRTUAIS: UMA PROPOSTA LÚDICA PARA O ENSINO DE TEMAS AMBIENTAIS. **Redin-Revista Educacional Interdisciplinar**, v. 7, n. 1, 2018.

MCHUGH, M. L. Interrater reliability: the kappa statistic. **Biochemica Médica**, 22 (3), 276-282. 2012.

PETER, Sophie et al. Tagging learning objects in Moodle for personalisation and re-use. In: **EdMedia+ Innovate Learning. Association for the Advancement of Computing in Education (AACE)**, 2011. p. 2259-2266.

PIERCE, Marlon E. et al. Social networking for scientists using tagging and shared bookmarks: a Web 2.0 application. In: **International Symposium on Collaborative Technologies and Systems**. IEEE, 2008. p. 257-266.

TANTAM, Digby. The machine as psychotherapist: impersonal communication with a machine. **Advances in Psychiatric treatment**, v. 12, n. 6, p. 416-426, 2006.

TILLAEV, Azamat. Ways to use modern information technologies in education. In: **AIP Conference Proceedings**. AIP Publishing, 2023.

VANBELLE, Sophie. A new interpretation of the weighted kappa coefficients. **Psychometrika**, v. 81, n. 2, p. 399-410, 2016.

VIANA, Josué et al. Aprendizagem Baseada em Equipe Aplicada no Ensino Remoto na Disciplina de Interação Humano-Computador. In: **Anais Estendidos do XX Simpósio Brasileiro de Fatores Humanos em Sistemas Computacionais**. SBC, 2021. p. 35-40.

WILSON, B. D. et al. Mememxgate: Unearthing latent content features for improved search and relevancy ranking across scientific literature. In: **AGU Fall Meeting Abstracts**. 2015. p. IN33A-1794.