

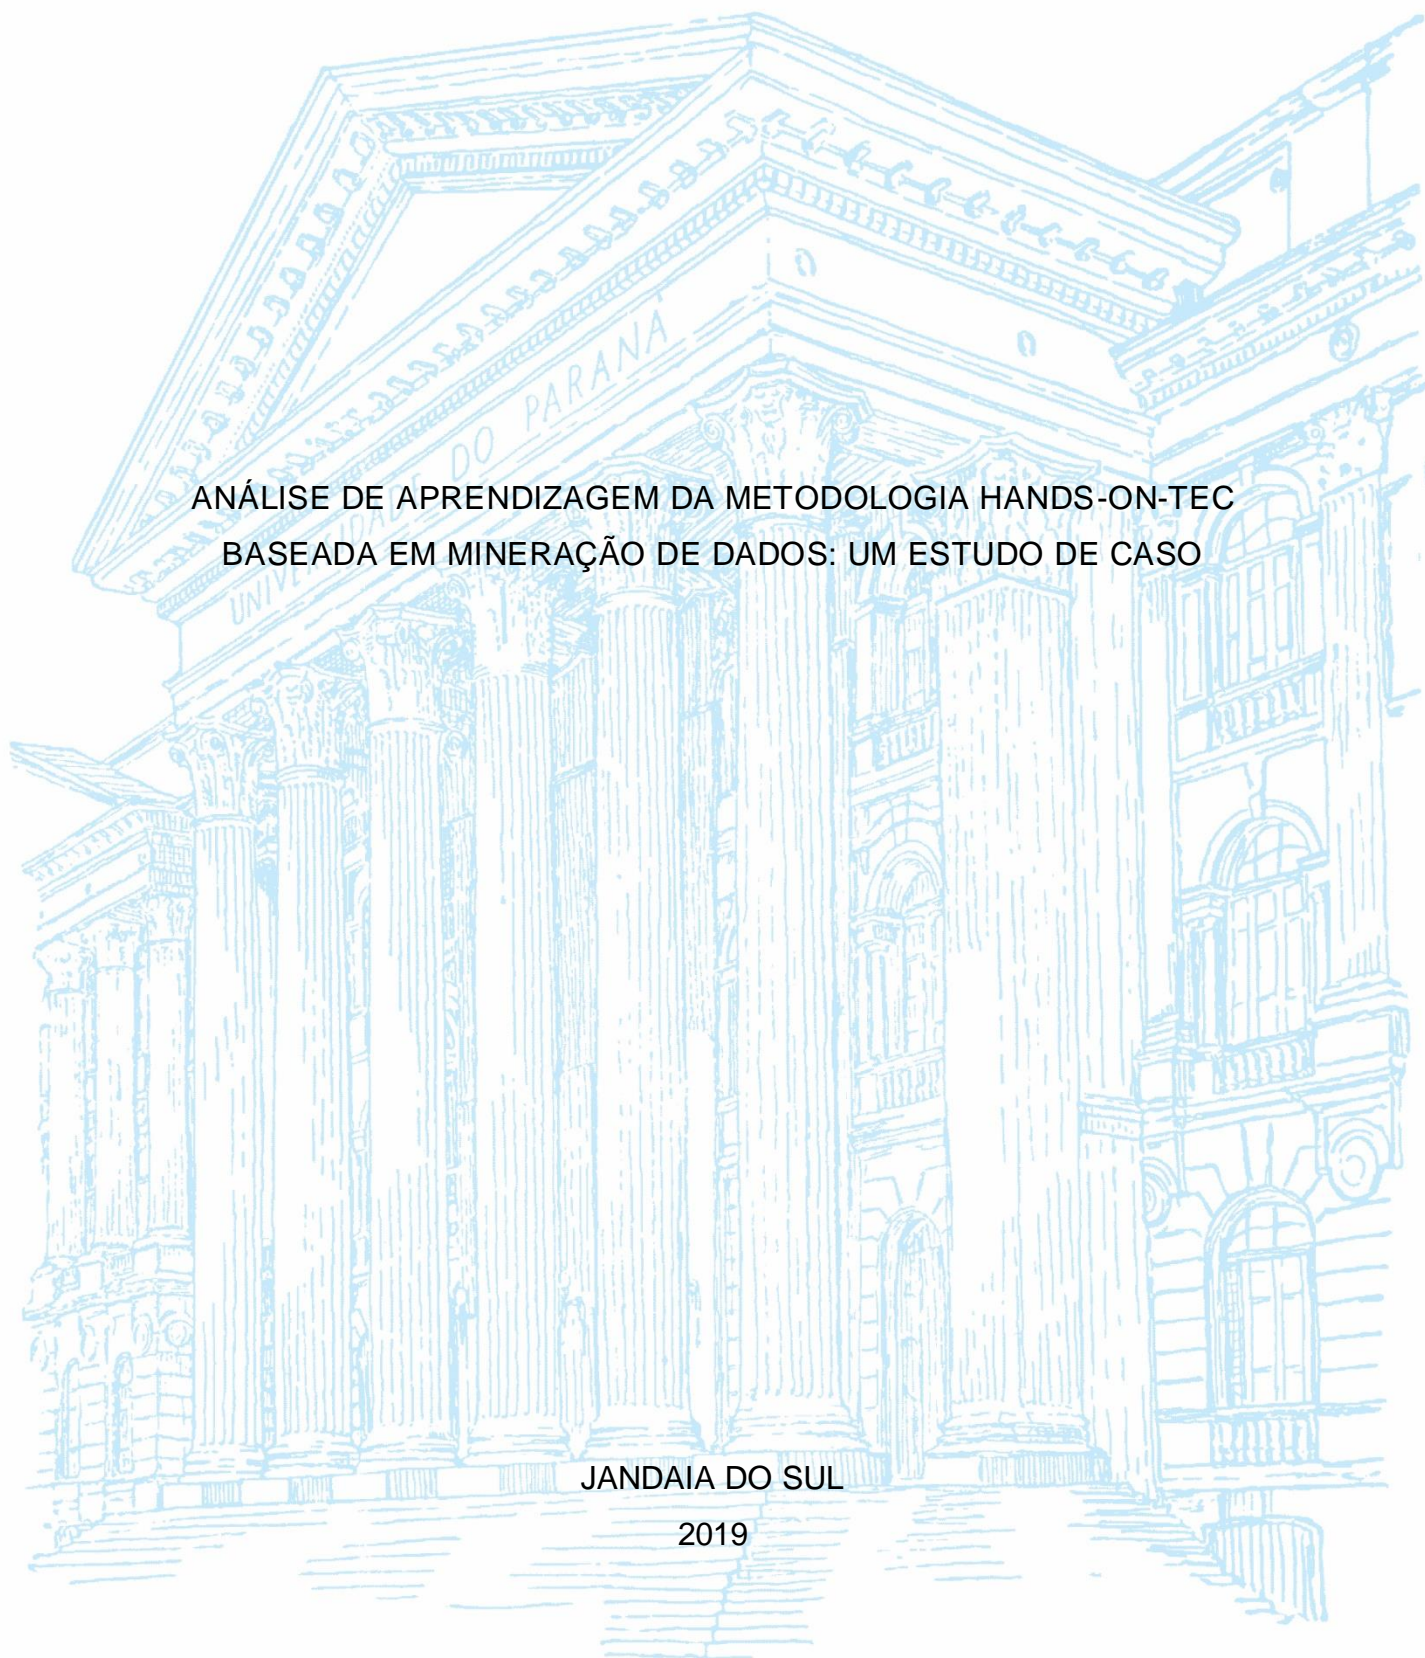
UNIVERSIDADE FEDERAL DO PARANÁ

INÊS BARÃO FERREIRA MIYAMOTO

ANÁLISE DE APRENDIZAGEM DA METODOLOGIA HANDS-ON-TEC  
BASEADA EM MINERAÇÃO DE DADOS: UM ESTUDO DE CASO

JANDAIA DO SUL

2019



INÊS BARÃO FERREIRA MIYAMOTO

ANÁLISE DE APRENDIZAGEM DA METODOLOGIA *HANDS-ON-TEC*  
BASEADA EM MINERAÇÃO DE DADOS: UM ESTUDO DE CASO

Monografia apresentada como requisito parcial para a obtenção do grau de Licenciada no Curso de Licenciatura em Computação, Campus Avançado em Jandaia do Sul da Universidade Federal do Paraná.

Orientador: Prof. Dr. Rodrigo Clemente Thom de Souza

JANDAIA DO SUL

2019

M685a Miyamoto, Inês Barão Ferreira  
Análise de aprendizagem da metodologia *hands-on-Tec* baseada em mineração de dados: um estudo de caso. / Inês Barão Ferreira Miyamoto. – Jandaia do Sul, 2019.  
49 f.

Orientador: Prof. Dr. Rodrigo Clemente Thom de Souza  
Trabalho de Conclusão do Curso (graduação) – Universidade Federal do Paraná. Campus Jandaia do Sul. Curso de Licenciatura em Computação.

1. *Learning analytics*. 2. Mineração de dados educacionais. 3. *Hands-on-Tec*. I. Souza, Rodrigo Clemente Thom de. II. Título. III. Universidade Federal do Paraná.

CDD 371.33



**UNIVERSIDADE FEDERAL DO PARANÁ**  
**PARECER Nº** 001/2019/2019/UFPR/R/JA/CCLC  
**PROCESSO Nº** 23075.078359/2019-32  
**INTERESSADO:** RODRIGO CLEMENTE THOM DE SOUZA, ADRIANO RODRIGUES MANSANERA,  
GIANCARLO ALFONSO LOVON CANCHUMANI

**TERMO DE APROVAÇÃO DE TRABALHO DE CONCLUSÃO DE CURSO**

**Título:** ANÁLISE DE APRENDIZAGEM DA METODOLOGIA *HANDS-ON-TEC* BASEADA EM MINERAÇÃO DE DADOS: UM ESTUDO DE CASO

**Autor/a:** Inês Barão Ferreira Miyamoto

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do grau no curso de Licenciatura em Ciência da Computação, aprovado pela seguinte banca examinadora.

- RODRIGO CLEMENTE THOM DE SOUZA
- ADRIANO RODRIGUES MANSANERA
- GIANCARLO ALFONSO LOVON CANCHUMANI

Jandaia do Sul, 19 de Novembro de 2019.



Documento assinado eletronicamente por **RODRIGO CLEMENTE THOM DE SOUZA**,  
**PROFESSOR 3 GRAU**, em 19/11/2019, às 17:38, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **ADRIANO RODRIGUES MANSANERA**,  
**PROFESSOR 3 GRAU**, em 19/11/2019, às 17:39, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **GIANCARLO ALFONSO LOVON CANCHUMANI**,  
**PROFESSOR 3 GRAU**, em 19/11/2019, às 17:39, conforme art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida [aqui](#) informando o código verificador **2315025** e o código CRC **F1BB4A84**.

## **AGRADECIMENTOS**

A todos os que, de alguma forma, contribuíram para o meu percurso acadêmico, mas com destaque aos seguintes.

Ao meu marido, que desde o início tem sido o meu maior incentivador, contribuindo significativamente para que eu chegasse até esta etapa.

À minha filha, que me inspira sempre a ser melhor em todos os aspectos, e por isso foi grande parte do motivo para eu ter retomado este caminho e não ter desistido.

Aos meus pais, avó e irmão, que, ainda que do outro lado do oceano, nunca deixaram de acreditar em mim e no meu potencial, e que se alegram a cada conquista minha.

Ao meu orientador, a quem recorro sempre que preciso de orientação, desde o início, por estar sempre pronto a auxiliar no que for necessário e, em especial, por tudo o que me ensinou.

Se nada plantares, nenhum fruto poderás colher.  
Se escolheres plantar com dedicação, comprometimento e responsabilidade,  
serão colhidos os frutos mais proveitosos, pois serão reflexo do processo.

(Autorial)

## RESUMO

O presente Trabalho de Conclusão de Curso foi realizado com o objetivo de fazer uma análise de aprendizagem relativa à aplicação da metodologia *Hands-on-Tec* no ensino de Ciências da Natureza a alunos do 4º e 5º anos do Ensino Fundamental I, de uma instituição de ensino não formal e de outra de ensino formal. Particularmente, pretendeu-se avaliar as contribuições da metodologia sobre aspectos comportamentais, econômicos e de fluência tecnológica. Para isso, dados demográficos, econômicos, de fluência tecnológica e comportamentais foram coletados, por meio de observação e questionários sobre a aplicação da *Hands-on-Tec*. A partir das respostas, criou-se uma tabela com 48 instâncias, correspondendo a cada criança, e 25 colunas, correspondendo aos atributos. As variáveis de saída são: “Concentração Melhorou”, “Conversa Menos”, “Comportamento Casa Melhorou”, “Concentração Maior Usando Tecnologias”, “Uso Tecnologias Melhorou”, “Aprende Melhor Com Tecnologias”, “Usa Tecnologias Sem Ajuda” e “Usa Tecnologias Fora Da HoT”. Aplicaram-se pré-processamentos e, posteriormente, algoritmos de mineração para classificação dos oito conjuntos de dados, um para cada variável de saída. Foram utilizados os seguintes classificadores: *OneR*, *JRip*, *J48*, *Random Tree*, *Logistic*, *Multilayer Perceptron*, *SMO* e *Naive Bayes*. Observou-se que os quatro primeiros algoritmos mencionados obtiveram o melhor desempenho, no geral. Concluiu-se que a metodologia influenciou positivamente no comportamento e concentração, mas principalmente na fluência tecnológica. Espera-se que o trabalho possa, futuramente, auxiliar e orientar educadores que tenham pretensão de utilizar a *Hands-on-Tec* com os seus alunos.

**Palavras Chave:** *Learning Analytics*. Mineração de Dados Educacionais. *Hands-On-Tec*.

## ABSTRACT

This work was carried out with the aim of applying learning analytics to data from the application of the Hands-on-Tec methodology for teaching Science to 4<sup>th</sup> and 5<sup>th</sup> grade elementary school students in non-formal and formal education. Particularly, it was intended to evaluate the contributions of the methodology for behavioral, economic and technological fluency aspects. To do that, demographic, economical, technological fluency and behavioral data were collected through observation and quizzes about the teaching method. From the answers, a table was created, with 48 instances, which correspond to each child, and 25 columns, representing the attributes. The output variables are: "Concentration Improved", "Less Conversation", "Home Behavior Improved", "More Concentration Using Technologies", "Technology Use Improved", "Learns Better With Technologies", "Uses Technologies Without Help", and "Uses Technologies Outside HoT". Pre-processing was applied and, afterwards, data mining algorithms for classifying eight datasets, one for each output variable. The classifiers were the following: *OneR*, *JRip*, *J48*, *Random Tree*, *Logistic*, *Multilayer Perceptron*, *SMO* and *Naive Bayes*. It was observed that the first four mentioned algorithms performed better, in general. The main conclusion was that Hands-on-Tec had a positive influence on behavior and concentration, but even more so on technological fluency. The main expectation for this work is that, in the future, it helps and guides educators who intend to use Hands-on-Tec for teaching their students.

**Keywords:** Learning Analytics. Educational Data Mining. Hands-on-Tec.

## SUMÁRIO

1.	INTRODUÇÃO .....	9
1.1.	Objetivos .....	10
1.2.	Justificativa .....	10
1.3.	Organização do trabalho.....	11
2.	REVISÃO DA LITERATURA .....	13
2.1.	Análise de Aprendizagem ( <i>Learning Analytics</i> ).....	13
2.2.	Descoberta de Conhecimento em Bases de Dados ( <i>Knowledge Discovery in Databases</i> ).....	14
2.3.	Mineração de Dados Educacionais .....	15
2.4.	Educação Formal, Não formal e Informal .....	18
2.5.	Ciências da Natureza no Ensino Fundamental I .....	22
2.6.	<i>Hands-on-Tec</i> .....	23
2.7.	Estado da Arte .....	25
3.	MATERIAL E MÉTODOS.....	29
3.1.	Caracterização da Pesquisa .....	29
3.2.	Universo da Pesquisa.....	29
3.3.	Instrumento de Pesquisa .....	29
3.4.	Procedimentos de Coleta de Dados .....	30
3.5.	Procedimentos de Análise de Dados.....	31
4.	RESULTADOS E DISCUSSÃO .....	34
4.1.	Observação das aulas .....	34
4.2.	Síntese dos dados selecionados.....	34
4.3.	Pré-processamento .....	35
4.4.	Mineração .....	35
5.	CONSIDERAÇÕES FINAIS .....	43

REFERÊNCIAS.....	45
APÊNDICE 1 – QUESTIONÁRIO SOBRE A HANDS-ON-TEC .....	48

## 1. INTRODUÇÃO

A análise de aprendizagem beneficia-se do poder dos avanços em mineração de dados, interpretação e modelagem para melhorar as concepções de ensino e aprendizagem e adaptar a educação a estudantes individuais com maior eficiência (JOHNSON; ADAMS; HAYWOOD, 2011).

A metodologia *Hands-on-Tec* é uma estratégia didático-pedagógica que utiliza Tecnologias Educacionais Móveis, como *tablets*, *laptops* e celulares, integrando-as à educação. Segundo Santos Rosa, Rosa e Sales (2014), “sem com isso, descartar formas de ensino com grande potencial pedagógico, como por exemplo, as técnicas *Hands-on* e a de Resolução de Problemas”. A incorporação de tecnologias digitais na educação “possui um histórico com dificuldades e ao mesmo tempo, repleto de tentativas dos que intensificam seus esforços para seu uso educacional” (SANTOS ROSA; ROSA; SALES, 2014).

O *KDD*, sigla para *Knowledge Discovery in Databases*, em português, Descoberta de Conhecimento em Bases de Dados, estabelece-se como a área de pesquisa que lida com a descoberta de conhecimento em conjuntos de dados gerados a partir de processos experimentais e observacionais. O *KDD* engloba uma série de etapas desde a seleção de dados até a interpretação do conhecimento descoberto a partir dos mesmos. Uma etapa do *KDD*, a mineração de dados, trata especificamente da extração de padrões geralmente “ocultos” nos dados (FAYYAD *et al.*, 1996).

Segundo Kubo e Botomé (2001), o processo de ensino-aprendizagem trata-se de um complexo sistema de interações comportamentais entre professores e alunos. Avanços recentes nos campos da Educação, Computação e Estatística, bem como a interação e atuação conjunta de profissionais dos três segmentos fizeram emergir recentemente a área de mineração de dados educacionais. Trabalhos como os de Romero e Ventura (2007), Baker e Yacef (2009), Romero *et al.* (2011), Angeli *et al.* (2017) evidenciam a importância dessa área.

### **1.1. Objetivos**

O objetivo geral deste trabalho é analisar dados educacionais provenientes da aplicação da metodologia *Hands-on-Tec*, utilizando algoritmos de mineração de dados. Especificamente, aplicar questionários a alunos do 4º e 5º anos do Ensino Fundamental I que aprenderam Ciências da Natureza com a metodologia *Hands-on-Tec*, no ensino formal e não formal, de forma a coletar dados educacionais, econômicos, comportamentais e de fluência tecnológica. Além disso, submeter esses dados a pré-processamentos, aplicar algoritmos de mineração de dados sobre os dados tratados, comparando-os entre si relativamente ao desempenho preditivo, e, com base nos resultados produzidos pelos algoritmos de mineração, realizar interpretações sobre a aplicação da metodologia e suas contribuições sobre aspectos comportamentais, econômicos, e de fluência tecnológica. Assim, também se pretende contribuir para melhorar a estratégia pedagógica da metodologia.

### **1.2. Justificativa**

A educação, bem como o processo educativo, deve ser orientada por metodologias que permitam atender aos objetivos propostos pelos docentes (BRIGHENTI; BIAVATTI; DE SOUZA, 2015). Conforme Nérice (1978, p.284), a metodologia do ensino pode ser compreendida como um “conjunto de procedimentos didáticos, representados por seus métodos e técnicas de ensino”, esse conjunto de métodos são utilizados com o intuito de alcançar objetivos do ensino e de aprendizagem, com a máxima eficácia e, por sua vez, obter o máximo de rendimento.

As mudanças que ocorreram na forma de ensino com o uso das tecnologias, os desafios impostos aos professores e as oportunidades com a inserção de novas formas e meios, exigem dos professores novos métodos de ensino. Volta-se a atenção para as transformações da sociedade e a necessidade de modificar as tradicionais formas de ensinar, de aprimorar constantemente as práticas e os saberes docentes (VAILLANT; MARCELO, 2012).

Como tal, é de importância significativa que as metodologias de ensino implementadas sejam analisadas quanto à sua eficiência, principalmente no que concerne aos resultados produzidos na aprendizagem dos alunos, para que o educador possa decidir se irá implementá-la nas suas aulas, ou se o método necessita de aprimoramentos.

Com base no último artigo apresentado no Estado da Arte (MASCHIO *et al.*, 2018), a mineração de dados educacionais tem sido aplicada com uma frequência bastante maior no ensino superior do que na educação básica. O penúltimo artigo dessa mesma seção (NAKANO, 2017) mostra que existem trabalhos sobre a metodologia abordada, embora sejam poucos. Além disso, após pesquisa de artigos de mineração de dados educacionais na educação não formal, notou-se a escassez desses últimos relativamente ao mesmo tipo de artigo na educação formal. Considera-se, por isso, que os fatores mencionados evidenciam a importância deste trabalho.

Neste contexto, o presente trabalho visa analisar dados educacionais provenientes da aplicação da metodologia *Hands-on-Tec*, utilizando algoritmos de mineração de dados, de forma a realizar uma análise de aprendizagem das contribuições da metodologia *Hands-on-Tec* sobre aspectos comportamentais, econômicos e de fluência tecnológica de crianças do 4º e 5º anos do Ensino Fundamental I. Essa análise deu-se com base em dados de questionários e observações, de forma a contribuir para uma maior compreensão e para o aprimoramento da estratégia pedagógica da metodologia *Hands-on-Tec*, beneficiando-se dos recentes avanços da área conhecida como mineração de dados. Espera-se que o trabalho possa, futuramente, auxiliar e orientar educadores que tenham pretensão de utilizar a *Hands-on-Tec* com os seus alunos.

### **1.3. Organização do trabalho**

Este trabalho é organizado em seções, como se segue: na seção 2, é apresentada a Revisão da Literatura, que inclui o Estado da Arte. Na seção 3, o material e métodos utilizados para desenvolver a pesquisa. Na seção 4, são

apresentados os resultados e realizada uma discussão sobre eles. Por fim, na seção 5, podem ser lidas as considerações finais, seguidas das referências.

## 2. REVISÃO DA LITERATURA

Nesta seção, são abordados os conceitos de *Learning Analytics*, *KDD*, Mineração de Dados Educacionais, Ensino Formal, Não formal e Informal, Ciências da Natureza no Ensino Fundamental I e a metodologia *Hands-on-Tec*, além de ser apresentado o Estado da Arte.

### 2.1. Análise de Aprendizagem (*Learning Analytics*)

A análise de aprendizagem (*Learning Analytics*) refere-se à interpretação de uma ampla variedade de dados produzidos por e para benefício de estudantes de forma a avaliar o progresso acadêmico, prever o desempenho futuro e identificar potenciais problemas (JOHNSON; ADAMS; HAYWOOD, 2011). Os dados são coletados a partir de ações explícitas dos alunos, como completar tarefas e fazer exames, e de ações tácitas, incluindo interações sociais online, atividades extracurriculares, publicações em fóruns de discussão, e outras atividades que não são diretamente avaliadas como parte do progresso educacional do estudante (JOHNSON; ADAMS; HAYWOOD, 2011).

De acordo com a *1st International Conference on Learning Analytics and Knowledge* (2011) (primeira Conferência Internacional de *Learning Analytics* e Conhecimento), *Learning Analytics* (LA) é a medição, coleção, análise e informação de dados sobre alunos e seus contextos, para fins de compreensão e otimização da aprendizagem e dos ambientes em que ela ocorre.

O foco da análise de aprendizagem é o processo de aprendizagem, o que inclui a análise da interação entre aluno, conteúdo, instituição e educador (LONG; SIEMENS, 2011).

Segundo Johnson, Adams e Haywood (2011, p. 26), “o objetivo do LA é permitir que professores e escolas adaptem oportunidades educacionais ao nível de necessidade e habilidade de cada discente”. A análise de aprendizagem beneficia-se do poder dos avanços em mineração de dados, interpretação e modelagem para melhorar as concepções de ensino e

aprendizagem e adaptar a educação a estudantes individuais com maior eficiência (JOHNSON; ADAMS; HAYWOOD, 2011).

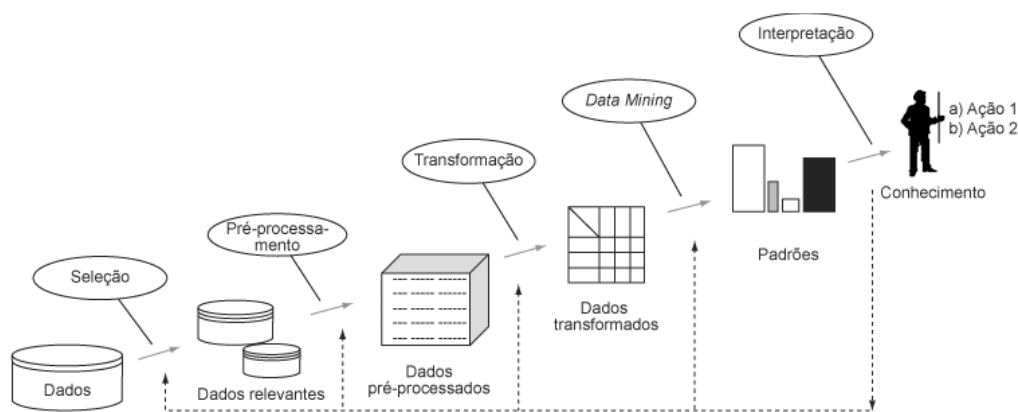
## **2.2. Descoberta de Conhecimento em Bases de Dados (*Knowledge Discovery in Databases*)**

*Knowledge Discovery in Databases (KDD)* é o processo não trivial de identificação de padrões válidos, inovadores, potencialmente úteis e compreensíveis, em dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). O fato de o *KDD* ser não-trivial significa que alguma pesquisa ou interferência está envolvida; isto é, não é uma simples computação de quantidades predefinidas, como o cálculo do valor médio de um conjunto de números. Neste caso, os dados são um conjunto de fatos (por exemplo, casos em uma base de dados) e o padrão é uma expressão em alguma linguagem que descreve um subconjunto dos dados ou um modelo aplicável ao subconjunto. Conseqüentemente, extrair um padrão também designa adequar um modelo aos dados; encontrar uma estrutura nos dados; ou, em geral, elaborar uma descrição de alto nível de um conjunto de dados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Sendo o *KDD* um processo, ele compreende diversas etapas, que envolvem preparação de dados, busca de padrões, avaliação do conhecimento e aprimoramento, todas repetidas em múltiplas iterações (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

As etapas do *KDD* são denominadas: seleção, pré-processamento, transformação, mineração de dados (*data mining*) e interpretação, pela ordem em que estão enumeradas, e estão ilustradas na figura 1.

FIGURA 1 – ETAPAS DO PROCESSO *KDD*



FONTE: Fayyad *et al.* (1996).

Segundo Fayyad, Piatetsky-Shapiro e Smyth (1996), a seleção de dados refere-se à etapa de preparação e seleção dos dados utilizados; o pré-processamento dos dados é a etapa de remoção ou atenuação de possíveis ruídos presentes nos dados selecionados; a transformação dos dados é a fase em que são aplicados tratamentos e transformações sobre os dados para melhor adequá-los à extração de padrões; a mineração de dados (*data mining*) trata-se da busca e extração de padrões nos dados por meio de algoritmos; por fim, a interpretação e avaliação dos resultados significa a análise da relevância e refinamento do conhecimento descoberto para o domínio em questão.

### 2.3. Mineração de Dados Educacionais

Mineração de dados (*data mining*) é uma das etapas do processo KDD, e pode ser definida como o processo de extração de relacionamentos e padrões implícitos, previamente desconhecidos e potencialmente úteis a partir de bases de dados (WITTEN; FRANK, 2005). Esses relacionamentos e padrões representam conhecimento valioso sobre os dados e, conseqüentemente, sobre o domínio do mundo real que eles representam (THOM DE SOUZA, 2013). O processo deve ser automático ou (mais frequentemente) semiautomático (WITTEN; FRANK, 2005).

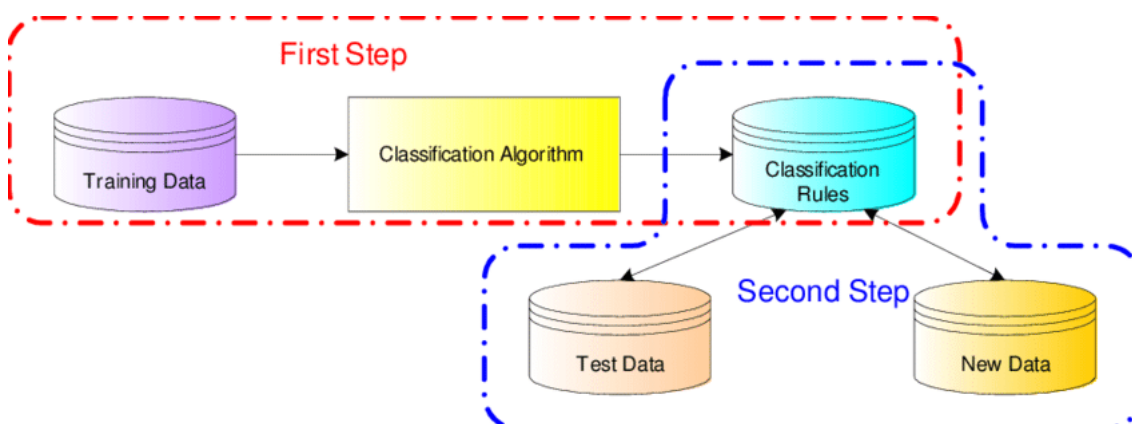
Na fase da mineração de dados, escolhe-se um algoritmo propício para cada aplicação (WITTEN; FRANK, 2005). O termo propício refere-se, principalmente, ao tipo de “tarefa” que o algoritmo deve realizar (objetivo do

processo). Usualmente, cada tarefa extrai um tipo de conhecimento diferente da base de dados e, portanto, utiliza algoritmos diferentes. De modo geral, o que estes algoritmos fazem é procurar por padrões presentes nos dados (THOM DE SOUZA, 2013).

Tradicionalmente, as tarefas de mineração de dados são divididas em aprendizagem supervisionada e não-supervisionada. Dentro da não-supervisionada, temos o agrupamento (*clustering*) que visa identificar e aproximar os registros similares: um agrupamento (ou *cluster*) é uma coleção de registros similares entre si, porém diferentes dos outros registros nos demais agrupamentos. Pode ser aplicado, por exemplo, em pesquisa de mercado, taxonomia de plantas e animais, entre outras (CAMILO; SILVA, 2009).

Já a aprendizagem supervisionada tem como principais tarefas a regressão, que estima o valor numérico de uma determinada variável analisando-se os valores das demais, e a classificação, que visa identificar a que classe uma determinada instância pertence, da seguinte forma: o modelo analisa o conjunto de instâncias fornecidas, cada uma já contida dentro de uma classe, a fim de 'aprender' como classificar um novo registro (CAMILO; SILVA, 2009). Esta última é a tarefa da qual se faz uso neste trabalho, e processa-se como ilustrado na seguinte imagem:

FIGURA 2 – ETAPAS DO PROCESSO DE CLASSIFICAÇÃO



FONTE: Paul; Tsai, 2004

Nos últimos anos, pesquisadores de uma variedade de áreas (incluindo ciência da computação, estatística, mineração de dados e educação) têm iniciado investigações sobre como a mineração de dados pode melhorar a educação e facilitar pesquisas nessa área. A mineração de dados educacionais (*Educational Data Mining, EDM*) é cada vez mais reconhecida como uma disciplina emergente (ROMERO; VENTURA, 2007). A *EDM* foca-se no desenvolvimento de métodos para explorar os tipos de dados provenientes de um contexto educacional. Esses dados provêm de diversas fontes, inclusive dados de ambientes de sala de aula tradicionais, software educacional, cursos online e avaliações formativas. Essas fontes providenciam cada vez maiores quantidades de dados, que podem ser analisados para abordar mais facilmente questões que não seriam viáveis anteriormente, envolvendo diferenças entre populações de estudantes, ou envolvendo comportamentos incomuns de alunos (ROMERO *et al.*, 2011).

A EDM tem sido aplicada com um vasto número de objetivos. Romero *et al.* (2011) fazem a distinção entre as seguintes aplicações ou tarefas:

- Comunicação com *stakeholders*: o objetivo é auxiliar administradores e educadores na análise de atividades e informação dos alunos em cursos;
- Manter e melhorar cursos: o objetivo é auxiliar administradores e educadores a decidirem como melhorar os cursos (conteúdos, atividades, *links*, etc.) usando informações em particular sobre a aprendizagem e a utilização por parte de cada aluno. As técnicas mais utilizadas são: associação, agrupamento e classificação;
- Sistemas de recomendação: o objetivo é recomendar aos estudantes o conteúdo (ou tarefas, ou *links*) mais apropriado para eles naquele momento. As técnicas mais utilizadas são: associação, agrupamento e classificação;
- Previsão de notas e resultados da aprendizagem: o objetivo é prever as notas finais ou outros tipos de resultado (tais como retenção de ano, ou habilidade futura de aprendizagem) de um aluno, com base em dados de atividades do curso. As técnicas mais utilizadas são: associação, agrupamento e classificação;

- Modelagem de alunos: a modelagem do usuário no domínio educacional possui algumas aplicações, incluindo, por exemplo, a detecção (frequentemente em tempo real) de estados e características do aluno, tais como satisfação, motivação, progresso de aprendizagem, ou determinadas categorias de problemas que têm um impacto negativo nos resultados da aprendizagem, e também influência, estilos de aprendizagem e preferências. O objetivo comum é criar um modelo de aluno a partir da informação de utilização. As técnicas mais utilizadas são, não apenas associação, agrupamento e classificação, mas também análises estatísticas, redes Bayes, modelos psicométricos e aprendizagem por reforço;
- Análise da estrutura do domínio: o objetivo é determinar a estrutura do domínio, utilizando a habilidade de prever o desempenho do estudante como medida de qualidade de um modelo de estrutura do domínio. O desempenho em provas ou dentro de um ambiente de aprendizagem é usado para esse propósito. As técnicas mais utilizadas são: regras de associação, métodos de agrupamento e algoritmos de busca.

Segundo Romero *et al.* (2011), a mineração de dados educacionais tem contribuído para a educação e pesquisa na educação de múltiplas formas; essas contribuições têm influenciado o pensamento na pedagogia e aprendizagem, e têm promovido o aprimoramento de *software* educacional, melhorando a capacidade do *software* de individualizar as experiências de aprendizado dos estudantes.

Na fase de mineração de dados, necessita-se definir a tarefa e o algoritmo a ser utilizado em função da tarefa proposta.

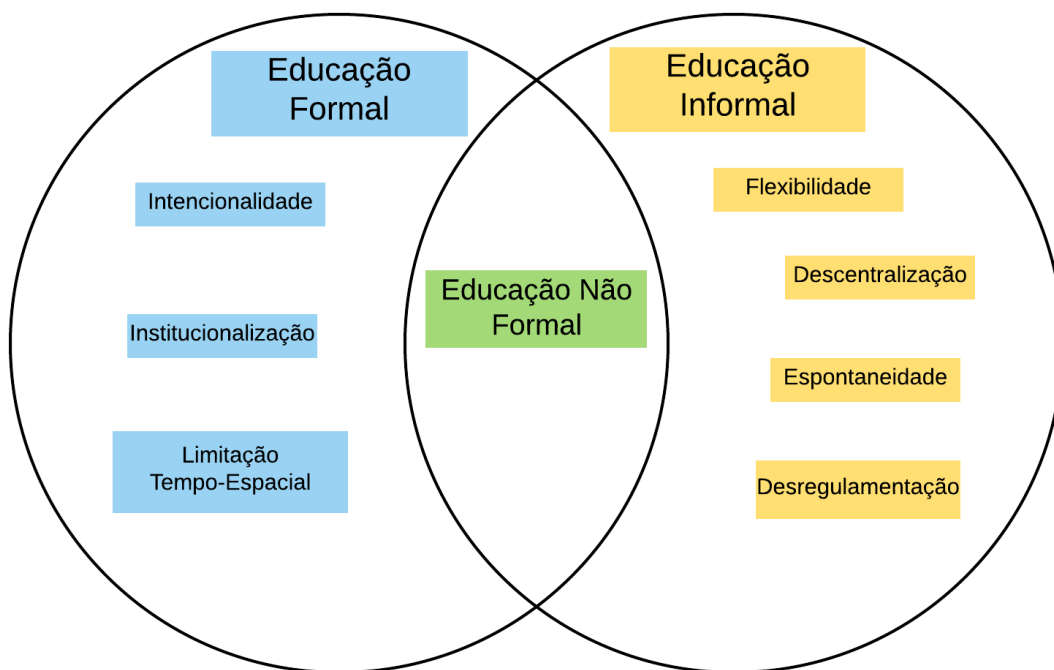
#### **2.4. Educação Formal, Não formal e Informal**

Brandão (2006), ao discutir educação, afirma tratar-se de um conceito polissêmico, que vai variar de acordo com tempos e espaços distintos, que se manifesta por modos de pensar e agir, uma vez que:

ninguém escapa da educação [...] não há uma única forma nem um único modelo de educação; a escola não é o único lugar em que ela acontece e talvez nem seja o melhor; o ensino escolar não é a única prática e o professor profissional não é seu único praticante (BRANDÃO, 2006, p. 9).

Além disso, esta pode ser identificada em suas diferentes formas: educação informal, educação formal e educação não formal. Para distinguir e demarcar as diferenças entre esses conceitos, a princípio podemos demarcar seus campos de desenvolvimento: a educação formal é desenvolvida nas escolas, com conteúdo pré-estabelecido; a informal é aquela na qual os indivíduos aprendem durante o processo de socialização - na família, bairro, clube, amigos, entre outros, carregada de valores e culturas próprias, de pertencimento e sentimentos herdados; e a educação não formal é aquela que se aprende por meio dos processos de compartilhamento de experiências, principalmente em espaços e ações coletivas cotidianas (GOHN, 2006).

FIGURA 3 – DELIMITAÇÃO CONCEITUAL ENTRE EDUCAÇÃO FORMAL, NÃO FORMAL E INFORMAL.



FONTE: Adaptado de Borges (2010)

Quanto aos resultados esperados em cada tipo de educação, na educação formal espera-se, além da aprendizagem efetiva, a certificação e titulação que capacitam os indivíduos a seguir para graus mais avançados. Na

educação informal, os resultados não são esperados, eles simplesmente acontecem a partir do desenvolvimento do senso comum nos indivíduos, senso este que orienta suas formas de pensar e agir espontaneamente. A educação não formal poderá desenvolver, como resultados, uma série de processos tais como (GOHN, 2006):

- Consciência e organização de como agir em grupos;
- Construção e reconstrução de concepção de mundo e sobre o mundo;
- Contribuição para um sentimento de identidade com uma dada comunidade;
- Formação do indivíduo para a vida e suas adversidades (não apenas a capacitação para entrar no mercado de trabalho);
- Quando presente em programas com crianças ou jovens adolescentes, resgata o sentimento de valorização de si próprio (que é mais conhecido como a autoestima); ou seja, dá condições aos indivíduos para desenvolverem sentimentos de autovalorização, de rejeição dos preconceitos que lhes são dirigidos, o desejo de lutarem para serem reconhecidos como iguais (enquanto seres humanos), dentro de suas diferenças (raciais, étnicas, religiosas, culturais etc.);
- Aquisição de conhecimento de sua própria prática - os indivíduos aprendem a ler e interpretar o mundo que os cerca.

A definição de educação não formal, de acordo com Gohn (1999), é expressa a partir de campos ou dimensões, e é a seguinte:

O primeiro [campo] envolve a aprendizagem política dos direitos enquanto cidadãos, isto é, o processo que gera a conscientização dos indivíduos para a compreensão de seus interesses e do meio social e da natureza que o cerca, por meio da participação em atividades grupais. Participar de um conselho de escola poderá desenvolver essa aprendizagem. O segundo, a capacidade dos indivíduos para o trabalho, por meio da aprendizagem de habilidades e/ou desenvolvimento de potencialidades. O terceiro, a aprendizagem e exercício de práticas que capacitam os indivíduos a se organizarem com objetivos comunitários, voltadas para a solução de problemas coletivos cotidianos [...]. O quarto, e não menos importante, é a aprendizagem dos conteúdos da escolarização formal, escolar, em formas e espaços diferenciados. Aqui o ato de ensinar se realiza de forma mais

espontânea, e as forças sociais organizadas de uma comunidade têm o poder de interferir na delimitação do conteúdo didático ministrado bem como estabelecer as finalidades a que se destinam aquelas práticas [...] (GOHN, 1999, p. 95-96).

Portanto, o processo de ensino e aprendizagem não se deve limitar apenas a espaços escolares, mas ele pode e deve acontecer em diversas outras circunstâncias e modos, por exemplo, em organizações não-governamentais, em instituições de medidas sócio-educativas, em empresas, nos hospitais, e outros espaços que deem lugar para o processo educativo.

A educação não formal, na perspectiva apresentada, vem se consolidando por meio de propostas de trabalho voltadas para as camadas mais pobres da população. Adolescentes e crianças em situação constante de risco constituem parte do grupo quando abordamos os sujeitos envolvidos em atividades de educação não formal, outra parte conta ainda com [...] crianças e adolescentes que já vivenciam o afastamento da escola formal, e, concomitantemente, uma aproximação com o mundo da rua. Portanto, analisando esse cenário é que podem ser propostas formas alternativas e/ou paralelas de trabalho em instituições educacionais não-formais (SIMSON; PARK; FERNANDES, 2001, p. 12).

As propostas educativas não-formais começaram a ampliar-se a partir dos anos 1960/70. Foram vários os fatores que propiciaram essas novas necessidades educacionais não escolares; segundo Trilla (2008), os principais foram: o aumento da demanda de educação em consequência da inclusão de setores sociais anteriormente excluídos dos sistemas educacionais; modificações no mundo do trabalho; alterações na instituição familiar; e crescente utilização dos meios de comunicação de massa.

No entanto, a educação não formal e a informal não têm o objetivo de substituir a escola, ou a educação formal, mas sim complementá-la, de forma a auxiliar na construção do cidadão, tornando-o mais crítico e capaz de perceber o seu papel ativo na sociedade.

## 2.5. Ciências da Natureza no Ensino Fundamental I

Ciências da Natureza é uma das disciplinas estudadas no Ensino Fundamental I, sendo que essa disciplina visa formar o aluno para interagir e atuar em diversos ambientes, compreender o conhecimento científico, conhecer o contexto histórico da ciência, e perceber questões de caráter cultural, social, ético e ambiental associadas à utilização de recursos naturais e do conhecimento científico e das tecnologias.

Segundo a Base Nacional Comum Curricular (BNCC):

[...] ao longo do Ensino Fundamental, a área de Ciências da Natureza tem um compromisso com o desenvolvimento do letramento científico, que envolve a capacidade de compreender e interpretar o mundo (natural, social e tecnológico), mas também de transformá-lo com base nos aportes teóricos e processuais das ciências (BRASIL. Base Nacional Comum Curricular, 2018, p. 319).

Os conteúdos abordados nesta componente curricular, no Ensino Fundamental, foram divididos em três unidades temáticas: a primeira, Matéria e Energia, contempla o estudo de materiais e suas transformações, fontes e tipos de energia, de forma a construir conhecimento sobre a natureza da matéria e sobre as diferentes formas de utilizar a energia; a segunda, Vida e Evolução, propõe o estudo de questões relacionadas aos seres vivos, às suas características, e à vida como fenômeno natural e social; por fim, na unidade temática Terra e Universo, dá-se a conhecer as características, como dimensão, composição, movimentos, e forças atuantes, da Terra, do Sol, da Lua, e de outros corpos celestes (BRASIL, BNCC, 2018). A BNCC (2018) também indica que as três unidades temáticas devem ser estudadas não apenas individualmente, pois elas estão interligadas, o que é evidenciado pelo estudo de temas importantes, como saúde, ambiente e tecnologia, abordados em todas as unidades.

No quadro seguinte, é possível comparar os diferentes conteúdos lecionados na disciplina de Ciências da Natureza, do 1º ao 5º ano do Ensino Fundamental I, em cada unidade temática.

QUADRO 1 – OBJETOS DE CONHECIMENTO DE CIÊNCIAS DA NATUREZA DO 1º AO 5º ANO DO ENSINO FUNDAMENTAL I

UNIDADE TEMÁTICA	OBJETOS DE CONHECIMENTO				
	1º ano	2º ano	3º ano	4º ano	5º ano
<b>Matéria e Energia</b>	Características dos materiais	Propriedades e usos dos materiais; Prevenção de acidentes domésticos	Produção de som; Efeitos da luz nos materiais; Saúde auditiva e visual	Misturas; Transformações reversíveis e não reversíveis	Propriedades físicas dos materiais; Ciclo hidrológico; Consumo consciente; Reciclagem
<b>Vida e Evolução</b>	Corpo humano e respeito à diversidade	Seres vivos no ambiente; Plantas	Características e desenvolvimento dos animais	Cadeias alimentares simples; Microorganismos	Nutrição do organismo; Hábitos alimentares; Integração entre os sistemas digestório, respiratório e circulatório
<b>Terra e Universo</b>	Escalas de tempo	Movimento aparente do Sol no céu; O Sol como fonte de luz e calor	Características da Terra; Observação do céu; Usos do solo	Pontos cardeais; Calendários, fenômenos cíclicos e cultura	Constelações e mapas celestes; Movimento de rotação da Terra; Periodicidade das fases da Lua; Instrumentos óticos

FONTE: Adaptada de BRASIL, BNCC (2018).

## 2.6. *Hands-on-Tec*

A metodologia *Hands-on-Tec* é uma estratégia didático-pedagógica que utiliza Tecnologias Educacionais Móveis, como *tablets*, *laptops* e celulares, integrando-as à educação, para ensino de Matemática e Ciências da Natureza no Ensino Fundamental. Essa metodologia baseia-se na técnica *Hands-on*, que consiste, principalmente, em possibilitar que o estudante participe da descoberta de objetos e fenômenos da natureza, o que estimula a imaginação e desenvolve o domínio da linguagem (SANTOS ROSA; ROSA, 2013). Além disso, a *Hands-on-Tec* também utiliza a Teoria de Resolução de Problemas, que possibilita a apresentação de situações reais e sugestivas que exijam dos alunos uma atitude ativa ou um esforço para buscar suas próprias respostas.

O foco desta metodologia não é a tecnologia, sendo que esta é usada apenas como um meio para favorecer e auxiliar o aluno na pesquisa e

aprendizagem sobre o conteúdo programático que deve ser estudado (SANTOS ROSA; ROSA, 2013).

Segundo Santos Rosa e Rosa (2013), as atividades da Hands-on-Tec estão divididas em três fases, explicitadas a seguir:

- Fase 01 – Divide-se em três etapas: apresentação, levantamento de hipóteses e experimentação. Na primeira etapa, o professor escreve no quadro o problema a ser estudado, questionando os estudantes, e apresenta o material que deve ser utilizado. Os alunos devem utilizar o material referido para buscar soluções para o problema, enquanto que o professor deverá apenas orientá-los. Na segunda etapa, os estudantes fazem grupos e discutem as suas ideias, registrando-as no laptop. A última etapa é onde acontece a experimentação, onde os estudantes testam as suas ideias para encontrarem uma solução para o problema;
- Fase 02 – O professor reúne todos os estudantes e solicita aos grupos que relatem as suas ideias antes do experimento, as dificuldades que encontraram e como resolveram o problema. Após os relatos, o professor questiona aos alunos se eles conseguem relacionar a atividade com a vida real, o cotidiano. Por fim, é mostrado um vídeo que relaciona os conceitos com o cotidiano;
- Fase 03 – Divide-se em duas etapas: pesquisa *online* e relatório individual. Os estudantes devem pesquisar na internet sobre os conceitos importantes, o significado de palavras e outras informações relevantes para o entendimento da atividade. A elaboração do relatório consiste em descrever o que fizeram, o que observaram, com uma estrutura que contemple a pergunta problema, as hipóteses, os materiais utilizados, os testes do experimento e a solução do problema.

No site da *Hands-on-Tec*, estão disponíveis as atividades para serem aplicadas pelos professores. Cada docente pode livremente adaptar as atividades e adequar os experimentos à sua aula, além de ter a possibilidade

de contribuir com o cadastro de novas atividades que estejam dentro da proposta da *Hands-on-Tec* (SANTOS ROSA; ROSA, 2013).

## 2.7. Estado da Arte

Nesta seção, são apresentados trabalhos recentes, por ordem cronológica, com temática semelhante a este trabalho, particularmente análise de aprendizagem com mineração de dados e, também, um trabalho sobre a metodologia *Hands-on-Tec*, além de outro que consiste no mapeamento sistemático da literatura relativo à mineração de dados educacionais.

Liu e Ruiz (2008) conduziram um estudo sobre o uso de mineração de dados na previsão de desempenho de alunos do K-12 (nos Estados Unidos, essa é a designação para todos os anos escolares desde o jardim de infância até o ano 12, último ano da educação básica) em testes sobre conteúdos relacionados com energia. Pretendeu-se prever o desempenho dos estudantes, ou seja, a porcentagem de respostas corretas. Dois algoritmos de mineração de dados, C4.5 e M5, foram usados para construir uma árvore de decisão e uma função linear de forma a prever os níveis de desempenho dos alunos. Um conjunto de fatores relativos ao conteúdo, contexto e demanda cognitiva dos itens e às notas dos alunos são responsáveis por prever o desempenho dos estudantes em itens de avaliação, sendo que as demandas cognitivas constituem a maior contribuição para a previsão. A árvore de decisão e a função linear indicaram as mesmas previsões.

Márquez-Vera, Romero e Ventura (2011) propuseram a aplicação de técnicas de mineração de dados para previsão de reprovações na escola. Foram utilizados dados sobre 670 estudantes do Ensino Fundamental, no México. Vários experimentos foram desenvolvidos na tentativa de melhorar a acurácia na previsão do desempenho final dos estudantes, mais especificamente, de quais estudantes reprovariam. No primeiro experimento, os 15 melhores atributos foram selecionados. Depois, foram aplicadas duas estratégias diferentes, de modo a resolver o problema de classificar dados desbalanceados: balanceamento e classificação sensível ao custo. Os resultados de cada uma das técnicas, usando 10 algoritmos de classificação e

10 de validação cruzada, são mostrados e comparados para selecionar a melhor abordagem para o problema. Concluiu-se que a classificação sensível ao custo é a melhor abordagem, já que obteve excelentes resultados de classificação na classe menor (alunos que reprovam) e na classe maior (alunos que passam).

Krpan e Stankov (2012) fizeram um estudo sobre o uso do *learning management system* Moodle, com o objetivo de agrupar alunos com características semelhantes, baseando-se em avaliações online e em papel. Foram coletados dados de um experimento conduzido numa faculdade de ciências, no qual foi monitorado o uso do Moodle por 52 estudantes em um curso de introdução à ciência da computação. Os alunos foram submetidos a uma análise diagnóstica, para determinar o que já conheciam, depois utilizaram o Moodle por três semanas para aprender os conteúdos, e por fim fizeram outro teste para verificar os conhecimentos adquiridos. Os dados coletados foram relativamente ao gênero e aos resultados do pré-teste e do teste final. Foi feita uma análise de correlação estatística sobre os dados e, posteriormente, foi aplicado um algoritmo de agrupamento. Os resultados mostraram que os alunos que desenvolveram mais atividades, tiveram notas baixas, o que os autores acreditam que pode ter vários motivos, como a falta de atenção, e consideram-nos como *outliers*. Os autores sugerem para futuras pesquisas o desenvolvimento de um módulo dinâmico para o Moodle, assim como a coleta de dados em tempo real e um sistema de recomendação para os estudantes.

Pesquisas mostram que o Ensino Fundamental é a fase em que os alunos começam a ser conscientes da importância do sucesso acadêmico e a pensar na faculdade. Cada vez mais alunos utilizam software educacional nessa fase da educação, e têm sido desenvolvidas formas de detectar aspectos específicos da aprendizagem e engajamento para esses ambientes de aprendizagem. Esses tipos de modelos podem fornecer informação adicional para prever a entrada na faculdade. San Pedro *et al.* (2013) fizeram uma previsão de entrada na faculdade a partir desses modelos de detecção, no contexto de 3747 estudantes que utilizavam o sistema ASSISTment, fazendo uma detecção potencialmente mais precisa do que as técnicas anteriores. Foi

possível distinguir entre um estudante que estudará na faculdade de um que não irá para a faculdade 68.6% do tempo.

Zaduski *et al.* (2017) realizou um trabalho que expõe as possibilidades de aprendizagem em um ambiente não formal denominado Unesp Aberta, com cursos oferecidos no formato MOOC, em um espaço virtual aberto, gratuito e totalmente acessível, sem tutoria ou certificação, no qual a construção de conhecimentos é possível e observada a partir da interação entre cursistas. Para verificar a eficácia dessa hipótese, a pesquisa foi subdividida em três estudos: conhecer o perfil dos participantes nesses ambientes, identificando quem são e quais são suas necessidades; averiguar o grau de satisfação dos cursistas em relação ao curso, aos materiais propostos, às interações existentes e a sua percepção sobre a aprendizagem obtida e identificar mecanismos de comunicação e interação entre aprendizes, tendo como base os fóruns de discussão e outros meios. A abordagem metodológica adotada foi a quanti-qualitativa, utilizando dois instrumentos: a observação não participante de três fóruns de discussão e um questionário semiestruturado enviado para todos os participantes dos cursos de ciências humanas. Foram analisados quantitativamente os 675 questionários considerados válidos, e, qualitativamente, com auxílio do software *Iramuteq*, as publicações feitas nos fóruns de discussão e as respostas dadas na pergunta aberta do questionário. O estudo proporcionou a identificação do perfil dos aprendizes, a compreensão de suas percepções em relação aos recursos educacionais disponibilizados e à estrutura geral dos cursos. Além disso, foi possível afirmar que foram encontrados indícios de aprendizagem no ambiente de educação não formal analisado.

Nakano (2017) apresentou um Trabalho de Conclusão de Curso que tinha em vista apresentar uma proposta que conduzisse ao uso de tecnologias digitais para contribuir com a aprendizagem da temática Linguagem Oral e Escrita (LOE) no 5º. ano da educação fundamental I. Partindo do pressuposto que as tecnologias digitais e seu vasto conjunto de ferramentas podem facilitar o aprendizado com vistas a construção do conhecimento de uma maneira interativa e por meio de recursos condizentes com o contexto tecnológico atual. Com a proposição de analisar como as tecnologias digitais podem contribuir

com a aprendizagem da temática “LOE” (Linguagem Oral e Escrita) no 5º ano do Ensino Fundamental I, desenvolveu um estudo de caso constituído da modalidade de Investigação Colaborativa numa instituição beneficente situada em Jandaia do Sul, no qual vivenciou uma intervenção pedagógica com 49 alunos do 5º ano, sob a supervisão de 2 professoras da instituição. Conseguiu identificar uma melhora na motivação e no engajamento dos alunos em relação à disciplina base, com a ajuda das tecnologias, o que permitiu concluir que metodologias que utilizam tecnologias digitais como intermediárias do processo de aprendizagem trariam bons resultados se mais frequentemente aplicadas.

Maschio *et al.* (2018) realizaram um trabalho cujo objetivo foi apresentar um Mapeamento Sistemático da Literatura (MSL) sobre o cenário brasileiro, utilizando o repositório da Comissão Especial de Informática na Educação, com relação a mineração de dados educacionais. Um dos resultados do mapeamento apontou um alto índice de exploração de dados oriundos da graduação em relação a análise dos dados da educação básica, que ainda tem relativamente poucos trabalhos de mineração de dados educacionais.

### **3. MATERIAL E MÉTODOS**

Nesta seção, são apresentados o material e os métodos utilizados na realização deste trabalho.

#### **3.1. Caracterização da Pesquisa**

Esta pesquisa enquadra-se no tipo de pesquisa descritiva, já que as técnicas de coleta de dados utilizadas foram a observação e a aplicação de questionários para descrever características dos alunos da Hands-on-Tec e estabelecer relações entre elas, e segundo Vergara (2000, p.47), a pesquisa descritiva expõe as características de determinada população ou fenômeno, estabelece correlações entre variáveis e define sua natureza.

A pesquisa também é aplicada, pois teve o intuito de identificar as contribuições da *Hands-on-Tec* para questões comportamentais e de fluência tecnológica, e segundo Thiollent (2009, p.36), a pesquisa aplicada concentra-se em torno dos problemas presentes nas atividades das instituições, organizações, grupos ou atores sociais. Está empenhada na elaboração de diagnósticos, identificação de problemas e busca de soluções.

#### **3.2. Universo da Pesquisa**

O universo da pesquisa compreende crianças do 4º e 5º anos do Ensino Fundamental I, estudantes de duas instituições educacionais, uma de Ensino Não Formal e outra de Ensino Formal, localizadas em duas cidades do norte do Paraná. Essas crianças constituem um total de 48, sendo que todas aprenderam conteúdos de Ciências da Natureza com a metodologia *Hands-on-Tec*.

#### **3.3. Instrumento de Pesquisa**

Para realizar a pesquisa, foram observadas algumas aulas nas quais foi aplicada a *HoT*, de forma a obter um panorama geral do desempenho dos alunos relativamente ao uso das tecnologias digitais (*tablet* e *laptop*) e do seu

comportamento. Porém, a observação foi feita apenas no ambiente de Ensino Não formal.

Além disso, foi aplicado um questionário, constituído por questões de natureza demográfica (preservando o anonimato de cada aluno), comportamental e de fluência tecnológica. No caso do questionário aplicado aos alunos do Ensino Formal, contemplava adicionalmente questões de caráter socioeconômico. Essas questões, no caso dos alunos do Ensino Não formal, já haviam sido respondidas num questionário socioeconômico previamente aplicado pela própria instituição.

Para elaboração dos questionários, foram considerados os objetivos deste trabalho, que serviram de base para a formulação das perguntas.

### **3.4. Procedimentos de Coleta de Dados**

Os dados utilizados para este trabalho são de natureza demográfica, socioeconômica, comportamental e educacional, sendo que estes foram coletados em turmas de 4º e 5º anos do Ensino Fundamental I, de duas instituições educacionais: uma de Ensino Não formal (ENF), e outra de Ensino Formal (EF).

Antes da coleta de dados, foi pedido aos pais dos alunos que assinassem um Termo de Consentimento Livre e Esclarecido (TCLE); as crianças cujos pais não assinaram não foram incluídas na pesquisa.

Para obter os dados, foi aplicado um questionário criado com a ferramenta “Formulários Google”, cujas perguntas foram elaboradas no sentido de averiguar se a *Hands-on-Tec* influenciou o comportamento e a fluência digital dos alunos, na percepção deles. As crianças responderam a este questionário escrevendo ou assinalando a opção que mais se adequava a cada um, preservando-se a identidade de cada um. A coleta de dados através do questionário ocorreu no primeiro semestre de 2019 para o ENF, e em setembro de 2019 para o EF.

Posteriormente, a assistente social da instituição de ENF forneceu alguns questionários respondidos pelas famílias das crianças, relativamente à

situação socioeconômica de cada família. Apenas uma minoria não entregou os questionários respondidos. Desses questionários econômicos, foram selecionadas as perguntas e respostas mais relevantes para a pesquisa, para que fossem utilizadas neste trabalho, e as perguntas fossem adicionadas ao questionário para os alunos do EF. A partir dessa seleção, foram obtidas as seguintes informações: se a mãe trabalha, se o pai trabalha, a situação de moradia (se é alugada, financiada ou própria), o número de cômodos da casa, o número de pessoas que moram na casa, e se recebe ajuda do governo (se sim, de que programas se beneficia).

### **3.5. Procedimentos de Análise de Dados**

Com todos os dados obtidos, elaborou-se uma tabela no *Excel*, com 48 instâncias, uma para cada um dos alunos que aceitaram, junto com os pais, participar da pesquisa; além de 25 atributos, referentes aos dados que foram obtidos sobre esses alunos. Os atributos são os seguintes:

1. “MF” (masculino ou feminino – M/F);
2. “Ano” (4º/5º);
3. “Período” (Manhã/Tarde);
4. “Celular” (S/N);
5. “Tablet” (S/N);
6. “Computador” (S/N);
7. “TV” (S/N);
8. “Moto” (S/N);
9. “Carro (S/N)”;
10. “MaeTrabalha” (se a mãe trabalha - S/N);
11. “PaiTrabalha” (se o pai trabalha - S/N);
12. “SitMoradia” (Alugada/Financiada/Própria);
13. “NumCômodos” (o número de cômodos da casa);
14. “NumPessoasMoradia” (número de pessoas que moram na casa);

15. “ProgramasGoverno” (se recebe ajuda através de algum programa do governo e qual - MCMV (Minha Casa Minha Vida)/BolsaFamília/LuzFraterna/TarifaSocialÁgua/N);
16. “DisciplinaFacilidade” (disciplina que tem mais facilidade – Português/Matemática/Ciências/Geografia/História/Artes/EdFísica/EnsinoReligioso);
17. “DisciplinaDificuldade” (disciplina que tem mais dificuldade – Português/Matemática/Ciências/Geografia/História/Artes/EdFísica/EnsinoReligioso);
18. “ConcentraçãoMelhorou” (se a concentração melhorou desde que iniciou a Hands-on-Tec – S/N);
19. “ConversaMenos” (se conversa menos com os colegas desde que começou a Hands-on-Tec – S/N);
20. “ComportamentoCasaMelhorou” (se o comportamento em casa melhorou desde que começou a Hands-on-Tec – S/N);
21. “ConcentraçãoMaiorUsandoTecnologias” (se fica mais concentrado utilizando tecnologias – S/N);
22. “UsoTecnologiasMelhorou” (se consegue usar tecnologias mais facilmente desde que começou a Hands-on-Tec – S/N);
23. “AprendeMelhorComTecnologias” (se aprende melhor usando tecnologias – S/N);
24. “UsaTecnologiasSemAjuda” (se usa tecnologias sem precisar de ajuda – S/N);
25. “UsaTecnologiasForaDaHoT” (se usa tecnologias para outras atividades fora da Hands-on-Tec – S/N).

A partir desses dados, foram criados 8 conjuntos de dados. Dos 25 atributos, os 17 primeiros foram usados como variáveis de entrada para todos os 8 conjuntos de dados. Os demais 8 atributos foram utilizados como variáveis de saída (classes), um a um para cada conjunto de dados, de modo a explicar as contribuições da aplicação da Hands-on-Tec. Dessas 8 variáveis de saída,

os atributos “ConcentraçãoMelhorou”, “ConversaMenos” e “ComportamentoCasaMelhorou” mostram a contribuição pelo aspecto comportamental, os atributos “UsoTecnologiasMelhorou”, “AprendeMelhorComTecnologias”, “UsaTecnologiasSemAjuda” e “UsaTecnologiasForaDaHoT” pelo aspecto da fluência tecnológica e o atributo “ConcentraçãoMaiorUsandoTecnologias” por ambos os aspetos.

Foi, também, elaborado um gráfico com a distribuição das respostas de cada aluno (S ou N) para cada variável de saída.

Para que pudesse ser efetuada a mineração dos dados educacionais, foi necessário converter a tabela em *Excel* para um arquivo com a extensão ‘.arff’, reconhecida pelo *software Weka*. Os dados contidos nesse arquivo foram pré-processados e, seguidamente, classificados pelos seguintes algoritmos:

- **OneR**, que usa o atributo de mínimo erro para predições (FRANK; HALL; WITTEN, 2016);
- **JRip**, que implementa o algoritmo *Ripper*, incluindo otimização global heurística do conjunto de regras (FRANK; HALL; WITTEN, 2016);
- **J48**, que é uma implementação de código aberto em Java do algoritmo C4.5, no *Weka*. Em cada nó da árvore, o algoritmo escolhe o atributo dos dados que mais efetivamente particiona o seu conjunto de amostras em subconjuntos tendendo a uma categoria ou a outra (FRANK; HALL; WITTEN, 2016);
- **Random Tree**, que constrói uma árvore que considera K atributos selecionados aleatoriamente em cada nó (FRANK; HALL; WITTEN, 2016);
- **Logistic**, que constrói e utiliza um modelo de regressão logística multinomial com estimador de cume (FRANK; HALL; WITTEN, 2016);
- **Multilayer Perceptron (MLP)**, que utiliza retro propagação para aprender um perceptron multicamadas para classificar instâncias;
- **SMO**, que é o algoritmo de Otimização Sequencial Mínima para treinar um classificador de vetor (FRANK; HALL; WITTEN, 2016);
- **Naive Bayes**, que é baseado no “Teorema de Bayes”, e calcula a probabilidade de um evento ocorrer dado que outro evento já ocorreu (FRANK; HALL; WITTEN, 2016).

Os classificadores foram utilizados com o parâmetro padrão do *Weka* e com validação cruzada *2-fold*.

O *hardware* utilizado foi um *laptop* Acer Aspire E 15, com processador Intel Core i5-5200U, 4GB de memória RAM, e 500 GB HDD, com o sistema operacional Windows 8.1.

## 4. RESULTADOS E DISCUSSÃO

Nesta seção, são mostrados os resultados e é feita uma discussão sobre eles. Para isso, dividiu-se em subseções, como se segue: observação das aulas, síntese dos dados selecionados, pré-processamento e mineração.

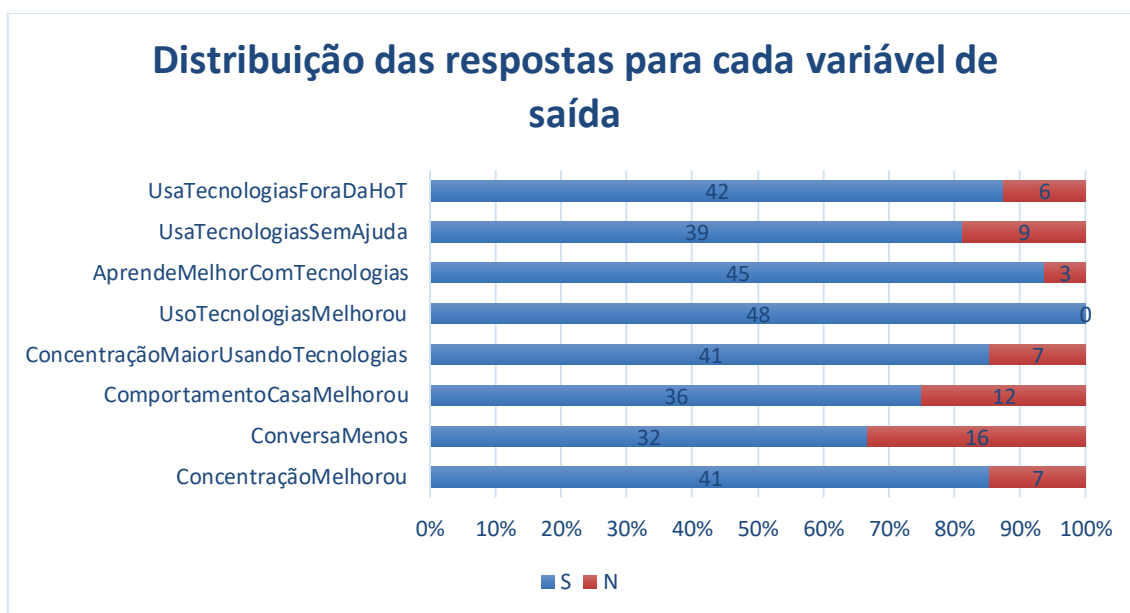
### 4.1. Observação das aulas

Quanto ao que foi observado durante a aplicação da metodologia, em geral, pôde-se constatar que as crianças parecem bastante familiarizadas com a *Hands-on-Tec*, e conseguem encontrar, sem muitas dificuldades, a informação relativa à atividade. Ainda existe alguma dificuldade de concentração nas tarefas atribuídas, por parte de alguns alunos. Observou-se, também, uma preocupação em saber se o conteúdo que encontraram, no momento de pesquisa, é adequado. No que diz respeito à realização de outras atividades, como responder ao questionário aplicado, os alunos aparentaram ter menos domínio das tecnologias se comparado às atividades da *Hands-on-Tec*.

### 4.2. Síntese dos dados selecionados

Na fase de seleção de dados, as respostas que as crianças forneceram para cada variável de saída foram distribuídas no gráfico 1, como se segue:

GRÁFICO 1 – DISTRIBUIÇÃO DAS RESPOSTAS PARA CADA VARIÁVEL DE SAÍDA



FONTE: O autor (2019).

Esse gráfico permitiu observar que a maioria das respostas foi “S” (sim) para todas as variáveis, destacando-se a melhora no uso de tecnologias, que gerou um consenso entre as crianças. É perceptível que os alunos consideraram que a *HoT* exerceu uma influência positiva maior na fluência tecnológica do que no comportamento e concentração. Além disso, existiu um consenso de que houve progresso no uso das tecnologias.

### 4.3. Pré-processamento

Durante o pré-processamento, no intuito de tratar dados ausentes (não respondidos pelas crianças), foi aplicado o filtro do *Weka* denominado *ReplaceMissingValues*, que substitui cada dado ausente pela média para atributos numéricos, e pela moda para os nominais.

### 4.4. Mineração

Após serem aplicados algoritmos de classificação aos dados pré-processados, os resultados do desempenho dos classificadores foram dispostos em 7 tabelas, uma para cada classe, de forma a comparar o desempenho dos diferentes algoritmos.

Para cada algoritmo, são determinados os valores relativos a cada medida de desempenho. Na primeira coluna, encontra-se a sua acurácia, que diz respeito à porcentagem de instâncias classificadas corretamente, e dá-se pela equação

$$Acurácia = \frac{VP+VN}{VN+VP+FN+FP} \times 100 \text{ (NASA; SUMAN, 2012),}$$

onde VP=Verdadeiros Positivos, VN=Verdadeiros Negativos, FP=Falsos Positivos, FN=Falsos Negativos.

Na segunda coluna, encontra-se a Taxa VP (ou *recall*), ou seja, a taxa de verdadeiros positivos, que diz respeito à probabilidade de uma instância classificada como S (positiva) ser, de fato, S. Calcula-se da seguinte forma:

$$Taxa VP = \frac{VP}{VP+FN} .$$

Na terceira coluna, tem-se o valor da Taxa FP, ou seja, a taxa de falsos positivos, que se refere à proporção de N (negativos) que foram incorretamente classificados como S (positivos). Calcula-se assim:

$$FP = \frac{FP}{VN+FP} \text{ (NASA; SUMAN, 2012).}$$

Na quarta coluna, tem-se a Precisão (Prec.), que corresponde à proporção de instâncias classificadas como S que efetivamente o eram. A fórmula é a seguinte:

$$Precisão = \frac{VP}{VP+FP} \text{ (NASA; SUMAN, 2012).}$$

Na sexta coluna, o *score* F1, que é uma combinação da precisão e da revocação, sendo calculado da seguinte forma:

$$F1 = \frac{2 \times Prec. \times Rev.}{Prec. + Rev.} \text{ (NASA; SUMAN, 2012).}$$

Por fim, a medida da curva COR (Característica de Operação do Receptor), que é uma curva de probabilidade, determina quanto o modelo é capaz de distinguir entre as classes. Quanto maior a curva, mais o modelo faz predições corretas. A curva COR é traçada no gráfico com a taxa de VP no eixo y e a taxa de FP no eixo x. (NASA; SUMAN, 2012).

Apesar de terem sido definidas 8 classes, uma para cada conjunto de dados, não foi elaborada uma tabela para a classe “Uso de Tecnologias

Melhorou”, pois 100% das respostas foram S (Sim), consequentemente a acurácia foi de 100% para todos os algoritmos.

Os melhores valores para cada medida de desempenho foram destacados em negrito. As tabelas são apresentadas a seguir:

TABELA 2 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “CONCENTRAÇÃO MELHOROU”

Classificador	Acurácia	Taxa VP ( <i>recall</i> )	Taxa FP	Prec.	F1	COR
OneR	83,333 %	0,976	<b>1</b>	0,851	0,909	0,488
JRip	<b>85,416 %</b>	<b>1</b>	<b>1</b>	0,854	<b>0,921</b>	0,458
J48	<b>85,416 %</b>	0,951	0,714	0,886	0,918	<b>0,664</b>
RandomTree	<b>85,416 %</b>	0,927	0,571	<b>0,905</b>	0,916	0,659
Logistic	70,833 %	0,756	0,571	0,886	0,816	0,537
MLP	83,333 %	0,951	0,857	0,867	0,907	0,617
SMO	83,333 %	0,976	<b>1</b>	0,851	0,909	0,488
NaiveBayes	81,250 %	0,951	<b>1</b>	0,848	0,897	0,481

FONTE: O autor (2019).

TABELA 3 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “CONVERSA MENOS”

Classificador	Acurácia	Taxa VP ( <i>recall</i> )	Taxa FP	Prec.	F1	COR
OneR	56,250 %	<b>0,844</b>	<b>1</b>	0,628	0,720	0,422
JRip	<b>66,666 %</b>	<b>0,844</b>	0,688	<b>0,711</b>	<b>0,771</b>	<b>0,617</b>
J48	<b>66,666 %</b>	<b>0,844</b>	0,688	<b>0,711</b>	<b>0,771</b>	<b>0,617</b>
RandomTree	54,167 %	0,750	0,875	0,632	0,686	0,442
Logistic	54,167 %	0,719	0,813	0,639	0,676	0,424
MLP	45,833 %	0,656	0,938	0,583	0,618	0,295
SMO	52,083 %	0,719	0,875	0,622	0,667	0,422
NaiveBayes	54,167 %	0,750	0,875	0,632	0,686	0,459

FONTE: O autor (2019).

TABELA 4 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “COMPORTAMENTO CASA MELHOROU”

Classificador	Acurácia	Taxa VP ( <i>recall</i> )	Taxa FP	Prec.	F1	COR
OneR	62,500 %	0,722	0,667	0,765	0,743	0,528
JRip	<b>72,916 %</b>	<b>0,944</b>	<b>0,917</b>	0,756	<b>0,840</b>	0,521
J48	70,833 %	0,778	0,500	<b>0,824</b>	0,800	0,597
RandomTree	70,833 %	0,806	0,583	0,806	0,806	0,579
Logistic	68,750 %	0,778	0,583	0,800	0,789	0,576
MLP	66,667 %	0,778	0,667	0,778	0,778	0,632
SMO	70,833 %	0,806	0,583	0,806	0,806	0,611
NaiveBayes	70,833 %	0,861	0,750	0,775	0,816	<b>0,690</b>

FONTE: O autor (2019).

TABELA 5 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “CONCENTRAÇÃO MAIOR USANDO TECNOLOGIAS”

Classificador	Acurácia	Taxa VP (recall)	Taxa FP	Prec.	F1	COR
OneR	79,167 %	0,927	1	0,844	0,884	0,463
JRip	<b>85,416 %</b>	<b>1</b>	<b>1</b>	<b>0,854</b>	<b>0,921</b>	0,458
J48	<b>85,416 %</b>	<b>1</b>	<b>1</b>	<b>0,854</b>	<b>0,921</b>	0,458
RandomTree	72,916 %	0,854	1	0,833	0,843	0,415
Logistic	72,916 %	0,829	0,857	0,850	0,840	0,345
MLP	64,583 %	0,732	0,857	0,833	0,779	0,411
SMO	70,833 %	0,805	0,857	0,846	0,825	<b>0,474</b>
NaiveBayes	70,833 %	0,805	0,857	0,846	0,825	0,432

FONTE: O autor (2019).

TABELA 6 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “APRENDE MELHOR COM TECNOLOGIAS”

Classificador	Acurácia	Taxa VP (recall)	Taxa FP	Prec.	F1	COR
OneR	<b>93,750 %</b>	<b>1</b>	<b>1</b>	<b>0,938</b>	<b>0,968</b>	<b>0,500</b>
JRip	83,333 %	0,889	1	0,930	0,909	0,496
J48	83,333 %	0,889	1	0,930	0,909	0,496
RandomTree	<b>93,750 %</b>	<b>1</b>	<b>1</b>	<b>0,938</b>	<b>0,968</b>	0,456
Logistic	85,417 %	0,911	1	0,932	0,921	0,289
MLP	91,667 %	0,978	1	0,936	0,957	0,393
SMO	<b>93,750 %</b>	<b>1</b>	<b>1</b>	<b>0,938</b>	<b>0,968</b>	<b>0,500</b>
NaiveBayes	91,667 %	0,978	1	0,936	0,957	0,144

FONTE: O autor (2019).

TABELA 7 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “USA TECNOLOGIAS SEM AJUDA”

Classificador	Acurácia	Taxa VP (recall)	Taxa FP	Prec.	F1	COR
OneR	<b>79,167 %</b>	<b>0,974</b>	<b>1</b>	0,809	<b>0,884</b>	0,487
JRip	75,000 %	0,897	0,889	0,814	0,854	0,476
J48	75,000 %	0,872	0,778	<b>0,829</b>	0,850	0,541
RandomTree	66,667 %	0,744	0,667	<b>0,829</b>	0,784	<b>0,543</b>
Logistic	62,500 %	0,718	0,778	0,800	0,757	0,467
MLP	70,833 %	0,821	0,778	0,821	0,821	0,399
SMO	66,667 %	0,769	0,778	0,811	0,789	0,496
NaiveBayes	66,667 %	0,795	0,889	0,795	0,795	0,463

FONTE: O autor (2019).

TABELA 8 – DESEMPENHO DOS CLASSIFICADORES PARA A CLASSE “USA TECNOLOGIAS FORA DA HOT”

Classificador	Acurácia	Taxa VP (recall)	Taxa FP	Prec.	F1	COR
OneR	<b>85,417 %</b>	<b>0,976</b>	<b>1</b>	0,872	<b>0,921</b>	0,488
JRip	79,167 %	0,881	0,833	0,881	0,881	0,536
J48	79,167 %	0,881	0,833	0,881	0,881	0,536
RandomTree	81,250 %	0,905	0,833	0,884	0,894	<b>0,601</b>
Logistic	77,083 %	0,857	0,833	0,878	0,867	0,532
MLP	77,083 %	0,857	0,833	0,878	0,867	0,468
SMO	83,333 %	0,929	0,833	<b>0,886</b>	0,907	0,548
NaiveBayes	83,333 %	0,952	<b>1</b>	0,870	0,909	0,486

FONTE: O autor (2019).

Relativamente ao desempenho dos classificadores, no geral, o *OneR*, o *J48* e o *JRip* apresentaram os melhores resultados. O *RandomTree* também se destacou em dois conjuntos de dados e obteve bons resultados no geral, embora não os melhores. Esse resultado denota que os classificadores com maior acurácia são os de regras e árvores de decisão.

Foram analisadas as regras e árvores de regras criadas pelos classificadores com melhor desempenho preditivo na classificação de cada conjunto de dados. As regras consideradas mais relevantes e adequadas estão representadas nas figuras seguintes:

FIGURA 4 – REGRAS DO JRIP PARA A CLASSE “CONCENTRAÇÃO MELHOROU”

JRIP rules:

=====

```
(Computador = S) and (Carro = N) and (ProgramasGoverno = N) => ConcentraçãoMelhorou=N (4.0/0.0)
=> ConcentraçãoMelhorou=S (44.0/3.0)
```

FONTE: Weka (2019)

FIGURA 5 – REGRAS DO JRIP PARA A CLASSE “CONVERSA MENOS”

JRIP rules:

=====

```
(Computador = S) => ConversaMenos=N (20.0/9.0)
=> ConversaMenos=S (28.0/5.0)
```

FONTE: Weka (2019)

FIGURA 6 – REGRAS DO J48 PARA A CLASSE “CONVERSA MENOS”

J48 pruned tree

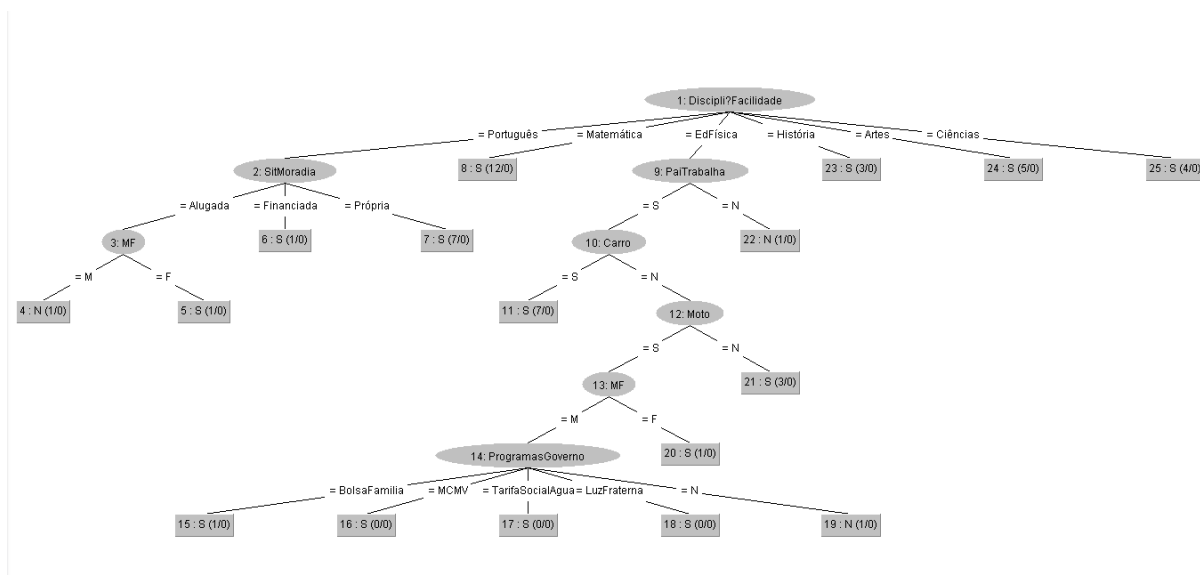
```

-----
Computador = S
| ProgramasGoverno = BolsaFamilia
| | NumPessoasMoradia <= 4: N (2.92/0.31)
| | NumPessoasMoradia > 4: S (3.33/0.33)
| ProgramasGoverno = MCMV: N (1.25/0.06)
| ProgramasGoverno = TarifaSocialAgua: N (2.5/0.13)
| ProgramasGoverno = LuzFraterna: S (1.25/0.19)
| ProgramasGoverno = N
| | NumPessoasMoradia <= 4: S (6.53/2.09)
| | NumPessoasMoradia > 4: N (2.22)
Computador = N: S (28.0/5.0)

```

FONTE: Weka (2019)

FIGURA 7 – ÁRVORE DO RANDOM TREE PARA A CLASSE “APRENDE MELHOR COM TECNOLOGIAS”



FONTE: Weka (2019)

Assim, é possível perceber que, para a classe “Concentração Melhorou”, se a criança tiver computador em casa, mas os pais não tiverem carro e ele

não receber ajuda do governo, não existiu um progresso na concentração; caso contrário, sim. Além disso, se não tiver computador em casa, a criança provavelmente conversa menos com os seus colegas durante a execução das atividades. É provável que isso se deva ao fato de o computador ser uma novidade a explorar para os alunos que geralmente não estão em contato com esse dispositivo, e assim eles estejam mais focados e conversem menos quando o utilizam nas aulas.

Para a classe “Aprende Melhor Com Tecnologias”, as regras mais relevantes são as seguintes: o aluno considera que a sua aprendizagem melhora usando tecnologias, se tem mais facilidade nas disciplinas de história, artes, matemática ou ciências. Como a Hands-on-Tec tem o propósito de ensinar Ciências, é possível que o aluno esteja habituado a aprender essa disciplina usando tecnologias e por isso o seu aprendizado seja mais rentável dessa forma. Adicionalmente, se a criança tiver mais facilidade na disciplina de Português e morar em casa própria ou financiada, e se acha Educação Física mais fácil e o pai trabalha e tem carro, também considera que aprende melhor usando tecnologias. O mesmo resultado acontece quando a disciplina mais fácil é Educação Física, e o pai trabalha, tem moto e recebe ajuda de algum programa do governo. Nesse caso, parece verificar-se que o aluno cujos pais têm melhores condições econômicas ou recebem ajuda de algum programa do governo aprende melhor com tecnologias, o que sugere que, se os pais têm condições de fornecer acesso às tecnologias para os seus filhos, então eles têm mais familiaridade com elas e aprendem a usar melhor o seu potencial – neste caso, para aprender. Pelas regras, pode-se, da mesma forma, entender que a ajuda que os programas do governo fornecem às famílias com mais dificuldades financeiras contribuem positivamente para a concentração e fluência digital das crianças.

Verificou-se, também a partir das regras criadas, que, para aspectos de fluência tecnológica, o gênero (masculino ou feminino) não teve impacto nos resultados.

Relativamente às demais variáveis de saída, os resultados dos melhores classificadores não produziram regras que parecessem ser relevantes ou até

mesmo que representassem, de fato, uma relação plausível entre variáveis de entrada e de saída.

## 5. CONSIDERAÇÕES FINAIS

Como descrito anteriormente, a importância deste trabalho reside no fato de ainda existirem relativamente poucos trabalhos de mineração de dados educacionais na Educação Básica e no Ensino Não Formal, e especialmente sobre a metodologia *Hands-on-Tec*, além da necessidade de compreender a influência que as abordagens metodológicas de ensino exercem na aprendizagem dos alunos.

Nos momentos de observação das aulas, tornou-se claro que as crianças estão familiarizadas com o processo da metodologia e que utilizam as tecnologias adequadamente durante essas atividades. Apesar disso, notou-se ainda alguma dificuldade no manuseio dos dispositivos eletrônicos em outros contextos, e dificuldade de concentração por parte de uma pequena parte das crianças.

De acordo com as respostas ao questionário, a maioria dos alunos não tem acesso a *tablet* em casa, o que permite perceber que o contato com esse aparelho foi uma das vantagens oferecidas pela *Hands-on-Tec*.

Verificou-se que os classificadores com melhor desempenho foram os de regras e árvores de decisão, especificamente *OneR*, *JRip*, *J48*, e em alguns casos o *RandomTree*. Esses algoritmos geraram regras que possibilitaram concluir que os alunos que não têm computador em casa se concentram mais e conversam menos quando o utilizam nas aulas da metodologia, sugerindo que isso se dá pelo contato com as tecnologias acontecer unicamente durante essas aulas. Além disso, os alunos cujos pais têm mais condições econômicas aprendem melhor com o uso das tecnologias. O mesmo ocorre quando recebem ajuda através de programas do governo. Atribuíram-se esses resultados à maior familiaridade das crianças com dispositivos eletrônicos, já que os pais têm mais possibilidade de os adquirir. Logo, a *Hands-on-Tec*, ao possibilitar o contato das crianças com essas tecnologias, tem vindo a contribuir positivamente para melhorar a sua concentração, comportamento e fluência tecnológica.

Concluiu-se que a *Hands-on-Tec* contribuiu de forma mais significativa para melhorar a fluência digital dos alunos do que para melhorar o comportamento e a concentração, tanto pela análise das respostas aos questionários, quanto pela observação.

Para trabalhos futuros, sugere-se aumentar o número de amostras – que foi uma limitação deste trabalho – e realizar uma comparação entre a classificação dos conjuntos de dados da educação formal e da não formal. Outras sugestões seriam implementar uma escala de 0 a 5 para o nível em que a *HoT* contribuiu para melhorar cada variável de saída; ou fazer uma análise da correlação das variáveis de entrada com maior influência nas respostas.

## REFERÊNCIAS

- 1st International Conference on Learning Analytics and Knowledge. Banff, Alberta, Canadá, 27 de fevereiro – 1 de março, 2011.
- Angeli, C., Howard, S. K., Ma, J., Yang, J., Kirschner, P. A. **Data mining in educational technology classroom research: Can it make a contribution?** Computers & Education, v. 113, p. 226-242, 2017.
- Baker, R. S., Yacef, K. **The state of educational data mining in 2009: A review and future visions.** JEDM: Journal of Educational Data Mining, n. 1(1), p. 3-17, 2009.
- Borges, C. J. P. **Perspectivas educacionais em revista: explorando as interfaces da educação social.** In: *Anales del 3º III Congreso Internacional de Pedagogia Social*, São Paulo (SP), 2010.
- Brandão, C. R. **O que é Educação Popular.** São Paulo: Brasiliense, 2006.
- Brasil, Ministério da Educação. **Base Nacional Comum Curricular – BNCC.** Brasília, DF, março de 2018.
- Brighenti, J., Biavatii, V. T., de Souza, T. R. **Metodologias de Ensino-Aprendizagem: Uma Abordagem Sob a Percepção dos Alunos.** Revista GUAL, Florianópolis, v. 8, n. 3, p. 281-304, set. 2015.
- Camilo, C. O., Silva, J. C. da. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas.** Instituto de Informática da Universidade Federal de Goiás, ago. 2009.
- Fayyad, U., Piatetsky-Shapiro, G., Smyth, P. **From Data Mining to Knowledge Discovery in Databases,** AI Magazine, v. 17, p. 37-54, 1996.
- Frank, E., Hall, M. A., Witten, I. H. **The WEKA Workbench: Online Appendix for “Data Mining: Practical Machine Learning Tools and Techniques”,** Morgan Kaufmann, 4<sup>th</sup> edition, 2016.
- Gohn, M. G. **Educação não formal e cultura política: impactos sobre o associativismo do terceiro setor.** São Paulo: Cortez, v. 71, 1999.
- Johnson, L., Adams, S., Haywood, K., (2011). **The NMC Horizon Report: 2011 K-12 Edition.** Austin, Texas: The New Media Consortium.
- Krpan, D., Slavomir, S. **Educational Data Mining for Grouping Students in E-learning System.** Faculty of Science, Split, Croácia, 2012.
- Kubo, O., Botomé, S. P. **Ensino-Aprendizagem: uma interação entre dois processos comportamentais.** Interação, Curitiba, v. 5, p. 123-132, 2001.
- Liu, X., Ruiz, M. E. **Using Data Mining to Predict K–12 Students’ Performance on Large-Scale Assessment Items Related to Energy.** Journal of Research in Science Teaching, v. 45, n. 5, p. 554-573, New York, 2008.

Long, P., Siemens, G. **Penetrating the Fog: Analytics in Learning and Education**. EDUCAUSE Review, v. 46, n. 5, p. 31-40, setembro/outubro, 2011.

Márquez-Vera, C., Romero, C., Ventura, S. **Predicting School Failure Using Data Mining**. 4<sup>th</sup> International Conference on Educational Data Mining (EDM), Holanda, 2011.

Maschio, P., Vieira, M., Costa, N., Melo, S., Júnior, C. **Um Panorama acerca da Mineração de Dados Educacionais no Brasil**. *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, 29(1), p. 1936, 2018.

Nakano, R. Y. **Integração de Tecnologias Digitais à Temática Linguagem Oral e Escrita no Ensino Fundamental I**. 105 f. Trabalho de Conclusão de Curso (Licenciatura em Computação) – Campus Jandaia do Sul, Universidade Federal do Paraná, 2017.

Nérice, I. G. **Didática geral dinâmica**. 10<sup>a</sup> ed., São Paulo: Atlas, 1987.

Paul, R., Tsai, W. **A Real-Time Community-of-Interest Framework for Command-and-Control Applications**. 19, 2004.

Romero, C., Ventura, S. (2007). **Educational data mining: A survey from 1995 to 2005**. *Expert Systems with Applications*, v. 33(1), p. 135–146.

San Pedro, M. O. Z., Baker, R., Bowers, A. J., Heffernan, N. T. **Predicting College Enrollment from Student Interaction with an Intelligent Tutoring System in Middle School**. *Proceedings of the 6<sup>th</sup> International Conference on Educational Data Mining*, p. 177-184, 2013.

Santos Rosa, S. dos, Rosa, V. **Hands-on-Tec (HoT): Proposta de uma sequência didática para o Ensino de Ciências Naturais e Matemática**. Portal Educacional Handstec.org, 2013. Disponível em <<http://www.handstec.org/>>.

Santos Rosa, S., Rosa, V., Sales, M. B. **Portal virtual Hands-on-Tec: recurso de autoria para professores da educação básica**. *Multimedia Journal of Research in Education*, v. 1, p. 1-6, 2014.

Simson, O. R. M., Park, M. B., Fernandes, R. S. **Educação não-formal: cenários da criação**. Campinas, São Paulo: Editora da Unicamp/ Centro de Memória, 2001.

Thiollent, M. **Pesquisa-ação nas organizações**. 2.ed. São Paulo: Atlas, 2009.

Thom de Souza, R. C. **Uma metodologia para classificação de dados nominais baseada no processo KDD: ênfase aos algoritmos culturais, estimação de distribuição e análise de correspondência múltipla**. Tese (Doutorado em Métodos Numéricos em Engenharia) – Universidade Federal do Paraná - UFPR, Curitiba, Paraná, 2013.

Trilla, J. **A educação não-formal**. In: ARANTES, Valéria Amorim (Org.). *Educação formal e não-formal*. São Paulo, Summus, 2008.

Vaillant, D., Marcelo, C. **Ensinando a ensinar. As quatro etapas de uma aprendizagem.** Curitiba: Editora da Universidade Tecnológica Federal do Paraná, 2012.

Witten, L. H., Frank, E. **Data mining: practical machine learning tools and techniques with Java Implementations.** Morgan Kaufmann Publishers, 2nd edition, San Francisco, CA, USA, 2005.

Zaduski, J. C. D., Schlünzen Junior, K., Nascimento dos Santos, D. A. do. **As possibilidades da educação não formal nos MOOCs.** Revista Ibero-Americana de Estudos em Educação, [S.l.], p. 1243-1266, ISSN 1982-5587, ago. 2017.

## APÊNDICE 1 – QUESTIONÁRIO SOBRE A HANDS-ON-TEC

### Questionário Hands-on-Tec

Algumas questões sobre você e sobre a sua opinião relativa a Hands-on-Tec. Seja sincero, escolha a opção que mais representa o que você pensa. O questionário é anônimo!

**\*Obrigatório**

**1. Menino ou menina? \***

Marcar apenas uma oval.

- Menino  
 Menina

**2. Ano \***

Marcar apenas uma oval.

- 4º ano  
 5º ano  
 Outro: \_\_\_\_\_

**3. Tem celular em casa? \***

Marcar apenas uma oval.

- Sim  
 Não

**4. Tem tablet em casa? \***

Marcar apenas uma oval.

- Sim  
 Não

**5. Tem computador em casa? \***

Marcar apenas uma oval.

- Sim  
 Não

**6. Tem televisão em casa? \***

Marcar apenas uma oval.

- Sim  
 Não

**7. Os seus pais ou seus responsáveis têm moto? \***

Marcar apenas uma oval.

- Sim  
 Não

**8. Os seus pais ou seus responsáveis têm carro? \***

Marcar apenas uma oval.

- Sim  
 Não

**9. Quantas pessoas moram em sua casa, incluindo você? \***

\_\_\_\_\_

**10. Das pessoas que moram com você, quais trabalham? \***

Marque todas que se aplicam.

- Pai  
 Mãe

Outro: \_\_\_\_\_

**11. Qual a situação da sua casa/apartamento? \***

Marcar apenas uma oval.

- Alugada  
 Financiada  
 Própria  
 Outro: \_\_\_\_\_

**12. Quantos cômodos tem a sua casa/apartamento? \***

\_\_\_\_\_

**13. Recebe ajuda de programas de governo? Se sim, qual(is)? \***

Marcar apenas uma oval.

- Bolsa Família  
 Minha Casa Minha Vida  
 Tarifa Social Água  
 Luz Cidadã  
 Nenhum  
 Outro: \_\_\_\_\_

14. Em qual disciplina da escola você tem mais facilidade? \*

Marcar apenas uma oval.

- Português  
 Matemática  
 Ciências  
 Geografia  
 História  
 Artes  
 Educação Física  
 Ensino Religioso  
 Outro: \_\_\_\_\_

15. Em qual disciplina da escola você tem mais dificuldade? \*

Marcar apenas uma oval.

- Português  
 Matemática  
 Ciências  
 Geografia  
 História  
 Artes  
 Educação Física  
 Ensino Religioso  
 Outro: \_\_\_\_\_

16. Desde que começou a Hands-on-Tec, a sua concentração nas atividades melhorou? \*

Marcar apenas uma oval.

- Sim  
 Não

17. Você conversa menos com os seus colegas durante a Hands-on-Tec? \*

Marcar apenas uma oval.

- Sim  
 Não

18. Desde que começou a Hands-on-Tec, notou melhora no seu comportamento em casa? \*

Marcar apenas uma oval.

- Sim  
 Não

19. Enquanto você usa o computador / tablet na Hands-on-Tec, você fica mais quieto e concentrado? \*

Marcar apenas uma oval.

- Sim  
 Não

20. Com a Hands-on-Tec, você consegue entender melhor como usar o computador e o tablet? \*

Marcar apenas uma oval.

- Sim  
 Não

21. Agora, você consegue aprender melhor com o computador e as tecnologias, comparando com antes? \*

Marcar apenas uma oval.

- Sim  
 Não

22. Você consegue usar o computador ou tablet sem ajuda? \*

Marcar apenas uma oval.

- Sim  
 Não

23. Você consegue usar o computador ou tablet para outras atividades fora da Hands-on-Tec (pesquisar para trabalhos da escola, por exemplo)? \*

Marcar apenas uma oval.

- Sim  
 Não