



# ConBRepro

X CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



02 a 04  
de dezembro 2020

## Análise de Aprendizagem da Metodologia *Hands-on-Tec* Baseada em Mineração de Dados

**Inês Barão Ferreira Miyamoto**

Engenharia de Produção – Universidade Estadual de Maringá

**Rodrigo Clemente Thom de Souza**

Engenharia de Produção – Universidade Estadual de Maringá

**Linyer Beatrys Ruiz Aylon**

Ciência da Computação – Universidade Estadual de Maringá

**Resumo:** O objetivo deste trabalho foi analisar dados educacionais provenientes da aplicação da metodologia *Hands-on-Tec*, utilizando algoritmos de mineração de dados. Para isso, foram aplicados questionários e observadas algumas aulas, de forma a coletar dados demográficos, socioeconômicos, comportamentais e educacionais. Esses dados foram coletados em turmas de 4<sup>o</sup> e 5<sup>o</sup> anos do Ensino Fundamental I, de duas instituições: uma de Ensino Não formal, e outra de Ensino Formal. Após aplicação de algoritmos de classificação, foram analisados os resultados dos classificadores com melhor desempenho. 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. Verificou-se que a *Hands-on-Tec* tem vindo a contribuir para melhorar a concentração, comportamento e fluência tecnológica, em especial esta última. 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:** Análise de Aprendizagem, Mineração de Dados Educacionais, *Hands-on-Tec*.

## Learning Analytics applied to the Hands-on-Tec Methodology Based on Data Mining

**Abstract:** This paper was carried out with the aim of analyzing educational data from the application of the *Hands-on-Tec* methodology, using data mining algorithms. To do that, quizzes and class observation were applied, so as to collect demographic, economical, behavioral and technological fluency data. Those data were collected from 4th and 5th grade classes, in formal and non-formal education. After applying the classification algorithms, the results of the best performing classifiers were analyzed. The following classifiers were implemented: *OneR*, *JRip*, *J48*, *Random Tree*, *Logistic*, *Multilayer Perceptron*, *SMO* and *Naive Bayes*. It was possible to observe that the first four mentioned algorithms performed better, in general. It was possible to conclude that *Hands-on-Tec* has been contributing to improve concentration, behavior and technological fluency, especially the latter. 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*.

## 1. Introdução

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).

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).

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.

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 (1987, 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.

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 formal e não-formal. Espera-se que o trabalho possa, além de contribuir para uma maior compreensão e para o aprimoramento da estratégia pedagógica, auxiliar e orientar educadores que tenham pretensão de utilizar a Hands-on-Tec com os seus alunos.

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

De acordo com a 1ª Conferência Internacional de *Learning Analytics and Knowledge* (2011), *Learning Analytics* (LA), ou Análise de Aprendizagem, 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).

LA 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).

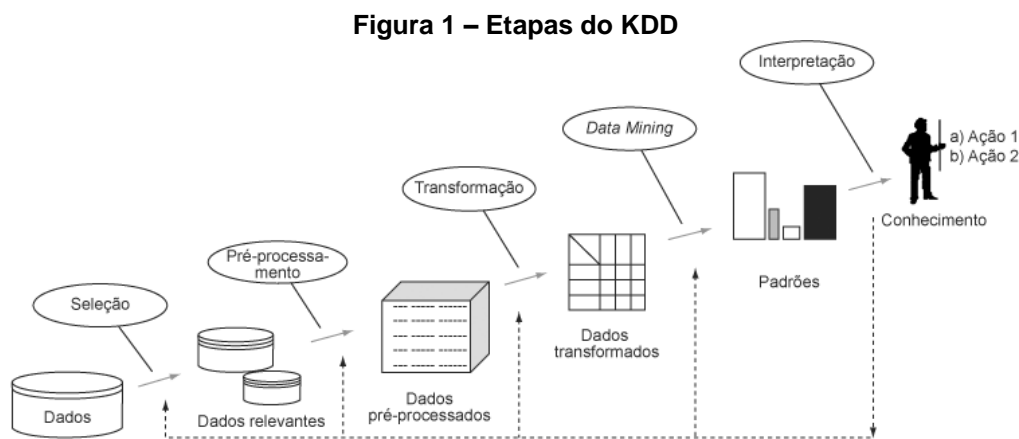
Segundo Johnson, Adams e Haywood (2011, p. 26), “o objetivo do LA é permitir que professores e escolas adaptem oportunidades educacionais ao nível de necessidade e habilidade de cada discente”. A análise de aprendizagem beneficia-se do poder dos avanços em mineração de dados, interpretação e modelagem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

### 3. 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.



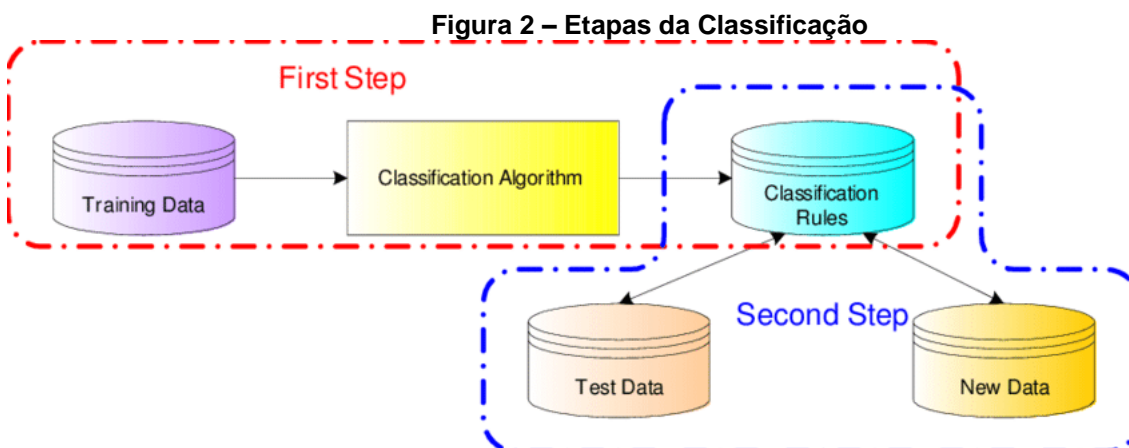
Fonte: Fayyad et al. (1996).

## 4. Mineração de Dados

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).

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.

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. A classificação é feita 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 figura 2.



Fonte: Paul e Tsai (2004)

## 5. Mineração de Dados Educacionais

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).

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.

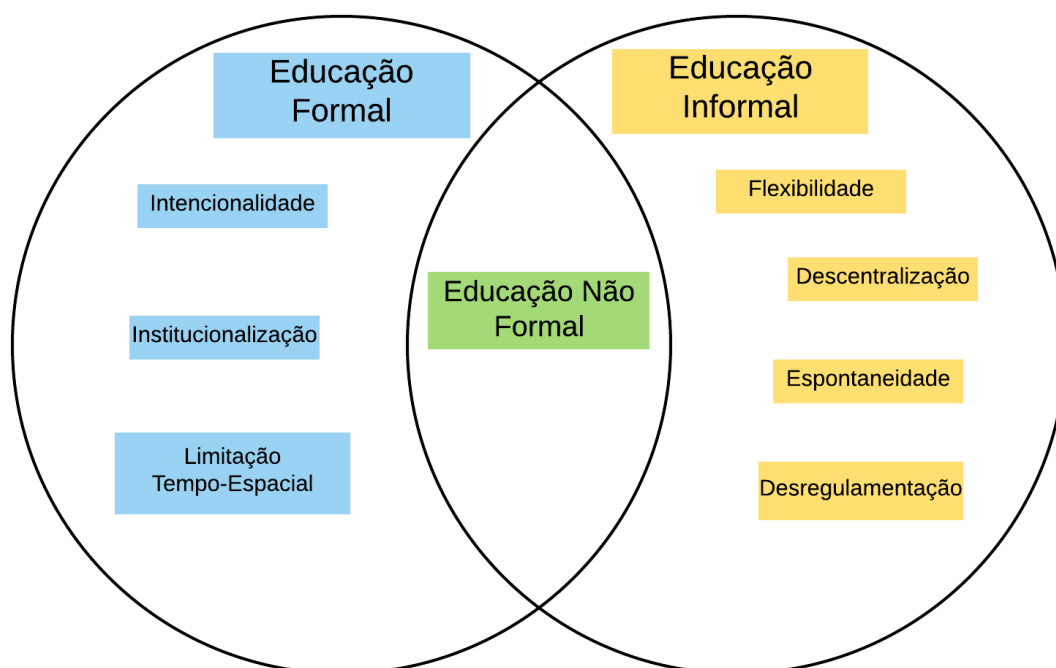
## 6. Educação Formal, Não Formal e Informal

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)

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.

## **7. 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).

As atividades da *Hands-on-Tec* estão divididas em três fases. Na primeira, o professor apresenta o problema aos alunos; estes buscam soluções, reúnem-se em grupos para discutir entre si e levantar hipóteses, e testam as suas teorias. Na segunda fase, os alunos, em grupos, relatam o processo feito na fase 1; o professor pede aos alunos que relacionem a atividade com o cotidiano e, em seguida, mostra um vídeo que ilustra essa relação. Já na terceira e última fase, as crianças pesquisam online sobre informações relevantes para a atividade e elaboram um relatório sobre todo o processo.

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).

## **8. Materiais e Métodos**

Os dados utilizados para este trabalho são de natureza demográfica, socioeconômica, comportamental e educacional, sendo que estes foram coletados em turmas de 4<sup>o</sup> e 5<sup>o</sup> 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. A identidade dos alunos foi preservada. Posteriormente, a assistente social da instituição de ENF forneceu alguns questionários respondidos pelas famílias das crianças, relativamente à situação socioeconômica de cada família. Foram adicionadas perguntas ao questionário aplicado no EF de forma a obter as mesmas respostas que os questionários socioeconômicos do ENF nos forneceram. Além disso, foram observadas algumas aulas da metodologia.


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

Os dados contidos nessa tabela foram pré-processados e, seguidamente, classificados pelos seguintes algoritmos: *OneR*, *JRip*, *J48*, *Random Tree*, *Logistic*, *Multilayer Perceptron* (MLP), *Sequential Minimal Optimization* (SMO) e *Naive Bayes*. Foi utilizado o software *Weka*.

## 9. Resultados e Discussão

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).

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.

Foram analisadas as regras e árvores de regras criadas pelos classificadores com melhor desempenho preditivo na classificação de cada conjunto de dados.

Através das regras criadas pelos algoritmos, percebeu-se 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.

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 em 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.

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*.

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, ainda que não os melhores. Pode-se observar isso nas seguintes tabelas.

**Tabela 1 – 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	1	0,851	0,909	0,488
JRip	<b>85,416 %</b>	1	1	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	1	0,851	0,909	0,488
NaiveBayes	81,250 %	0,951	1	0,848	0,897	0,481

Fonte: Os autores (2019).

**Tabela 2 – 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>	1	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: Os autores (2019).

**Tabela 3 – 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: Os autores (2019).

Tabela 4 – 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	<b>1</b>	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	<b>1</b>	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: Os autores (2019).

Tabela 5 – 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	<b>1</b>	0,930	0,909	0,496
J48	83,333 %	0,889	<b>1</b>	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	<b>1</b>	0,932	0,921	0,289
MLP	91,667 %	0,978	<b>1</b>	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	<b>1</b>	0,936	0,957	0,144

Fonte: Os autores (2019).

Tabela 6 – 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: Os autores (2019).

Tabela 7 – 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: Os autores (2019).

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). Conseqüentemente, a acurácia foi de 100% para todos os algoritmos.

Esse resultado denota que os classificadores com maior acurácia são os de regras e árvores de decisão.

## 10. Considerações Finais

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 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

- 1ª Conferência Internacional de *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: **Anais do 3º III Congresso Internacional de Pedagogia Social**, São Paulo (SP), 2010.
- BRANDÃO, C. R. O que é Educação Popular. São Paulo: Brasiliense, 2006.
- 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.; DA SILVA, J. C. 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.
- GOHN, M. G. Educação não-formal, participação da sociedade civil e estruturas colegiadas nas escolas. **Ensaio: Avaliação e Políticas Públicas em Educação**, v. 4, n. 50, 2006.
- JOHNSON, L.; ADAMS, S.; HAYWOOD, K. The NMC Horizon Report: 2011 K-12 Edition. Austin, Texas: The New Media Consortium, 2011.
- KUBO, O.; BOTOMÉ, S. P. Ensino-Aprendizagem: uma interação entre dois processos comportamentais. **Interação**, Curitiba, v. 5, p. 123-132, 2001.
- LONG, P.; SIEMENS, G. Penetrating the Fog: Analytics in Learning and Education. **EDUCAUSE Review**, v. 46, n. 5, p. 31-40, 2011.
- NÉRICE, I. G. Didática geral dinâmica. 10ª ed., São Paulo: Atlas, 1987.
- PAUL, R.; TSAI, W. A Real-Time Community-of-Interest Framework for Command-and-Control Applications, n. 19, 2004.
- ROMERO, C.; VENTURA, S. Educational Data Mining: A survey from 1995 to 2005. **Expert Systems with Applications**, v. 33(1), p. 135–146, 2007.
- SANTOS ROSA, S.; 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.
- 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**. Curitiba, 160 p., 2013. Tese (Doutorado em Métodos Numéricos em Engenharia) – Universidade Federal do Paraná.
- TRILLA, J. A educação não-formal. In: **ARANTES, 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**, 2ª ed., São Francisco, CA, USA, 2005.