

## Descoberta de Indicadores e Padrões nos Participantes do ENEM

Allan Markoski

allanmarkoki@hotmail.com

Universidade Federal de Santa Maria – UFSM

Leonardo Zancanaro

nadobz@gmail.com

Universidade Federal de Santa Maria - UFSM

Patrick Andrei Caron Guerra

patrickguerra@mail.ufsm.br

Universidade Federal de Santa Maria - UFSM

Cristiano Bertolini

cbertolini@gmail.com

Universidade Federal de Santa Maria - UFSM

Sidnei Renato Silveira

sidneirenato.silveira@gmail.com

Universidade Federal de Santa Maria - UFSM

### **Resumo**

A mineração de dados passou a ser amplamente utilizada nos últimos anos, possibilitando a obtenção de padrões e características sobre grandes volumes de dados. Nesse contexto, este artigo apresenta a utilização de técnicas de mineração de dados, para obtenção de indicadores, que possam estar relacionados ao desempenho dos participantes do ENEM (Exame Nacional do Ensino Médio), do ano de 2014, além de utilizar consultas no formato SQL (Structured Query Language) para verificar padrões encontrados com mineração de dados.

**Palavras-Chave:** *Mineração de Dados, ENEM, Consultas SQL.*

### **Abstract.**

Data mining has become widely used in last years. making it possible to obtain patterns and characteristics on a large volume of data. In this way, this paper aims to use data mining techniques to obtain indicators, which may be related to the performance of ENEM participants, for the year 2014. In addition, we use SQL queries to check patterns encountered with data mining.

**Keywords:** *Data Mining, ENEM, SQL Queries.*

## 1. INTRODUÇÃO

Atualmente existem milhares de Bases de Dados Abertas, que podem ser utilizados livremente para análise. Os dados abertos podem ser utilizados e distribuídos por qualquer tipo de pessoas, físicas ou jurídicas, mas exige-se a citação das fontes originais. Nesse sentido, surge a necessidade de métodos que permitam a análise dos dados para tentar encontrar padrões relevantes que possam contribuir para a tomada de decisão e modificações nos processos, entre outros aspectos.

Nesse contexto, este artigo apresenta uma proposta de utilização de técnicas de mineração de dados sobre a Base de dados Abertos (Microdados) do ENEM (Exame Nacional do Ensino Médio) de 2014 para, posteriormente, realizar a comparação da árvore de decisão gerada pelo algoritmo de mineração, externando suas regras por meio de consultas SQL (*Structured Query Language*), visando verificar a conformidade ou não com a totalidade dos dados da base (ENEM, 2018).

## 2. REFERENCIAL TEÓRICO

Esta seção apresenta o embasamento teórico, referente à análise de dados abertos, bem como da utilização da mineração de dados, além de apontar as metodologias de discretização e avaliação dos dados dos participantes, utilizadas neste trabalho.

### 2.1. Análise de Dados Abertos

De acordo com informações do *Open Definition* (2014), dados abertos são dados que podem ser livremente utilizados, isto é, reutilizados e distribuídos por qualquer pessoa, sujeitos no máximo, a exigência de citar a fonte original e compartilhar com as mesmas licenças em que as informações foram inicialmente apresentadas.

Apesar de o movimento de dados abertos ter sido estimulado mais recentemente, o termo “Dados Abertos” apareceu em 1995 em um documento de uma agência científica americana, abordando a divulgação de dados ambientais e geofísicos (CHIGNARD, 2013). Nesse documento, os autores promoveram uma completa e aberta troca de informações científicas entre diferentes países como um pré-requisito para a análise e a compreensão de fenômenos naturais globais.

Além disso, outro fator importante para o movimento de dados abertos aconteceu em dezembro de 2007. Pensadores e ativistas da Internet se reuniram para definir o conceito de Dados Abertos Públicos (ou Governamentais) (CHIGNARD, 2013). A base da reunião consistiu no conceito de que dados governamentais são de propriedades comuns, da mesma forma que as ideias científicas. A visão de Dados Abertos Governamentais foi fortalecida em 2008, quando na época, o presidente Barack Obama fez um memorando falando sobre Transparência e Dados Governamentais (OBAMA, 2008), criando assim, o *Data.gov*, com o objetivo de disponibilizar um portal de dados abertos no qual os dados do governo norte-americano poderiam ser acessados na Internet por qualquer cidadão.

Observa-se que, o Brasil também não ficou para trás no conceito sobre Dados Abertos. Nosso país, em 2011, foi um dos fundadores da *Open Government*

*Partnership*, que atualmente conta com 65 países. Criou também o DADOS.GOV.BR, portal que disponibiliza dados governamentais seguindo o mesmo princípio de dados abertos. A Administração Pública Federal, por meio da Lei de Acesso à Informação, reconheceu, no artigo 8º, a necessidade de disponibilizar dados em formato aberto (BRASIL, 2011).

## 2.2. Análise de Dados Usando Mineração de dados

O modelo tradicional para transformação dos dados em informação e, posteriormente, em conhecimento, consiste em um processamento manual de todas as informações por especialistas que, então, produzem relatórios que deverão ser analisados. Na grande maioria das situações, devido ao grande volume de dados, esse processo manual se torna impraticável (FAYYAD, 1996).

Ainda segundo Fayyad (1996), o KDD (*Knowledge Discovery in Databases* ou Descoberta de Conhecimento nas Bases de Dados) é uma tentativa de solucionar o problema causado pela chamada “era da informação”: a sobrecarga de dados. Nesse contexto, a descoberta de conhecimento em bases de dados (KDD) pode ser definida como o processo de extração de informação a partir de dados registrados em uma base de dados, um conhecimento implícito, previamente desconhecido, potencialmente útil e compreensível (GOLDSCHMIDT, 2005). O conceito mais utilizado para o termo KDD é de Fayyad (1996), que o define como “um processo não trivial de identificação de novos padrões válidos, úteis e compreensíveis”, sendo a mineração de dados uma das etapas desse processo, como demonstrado na Figura 1.

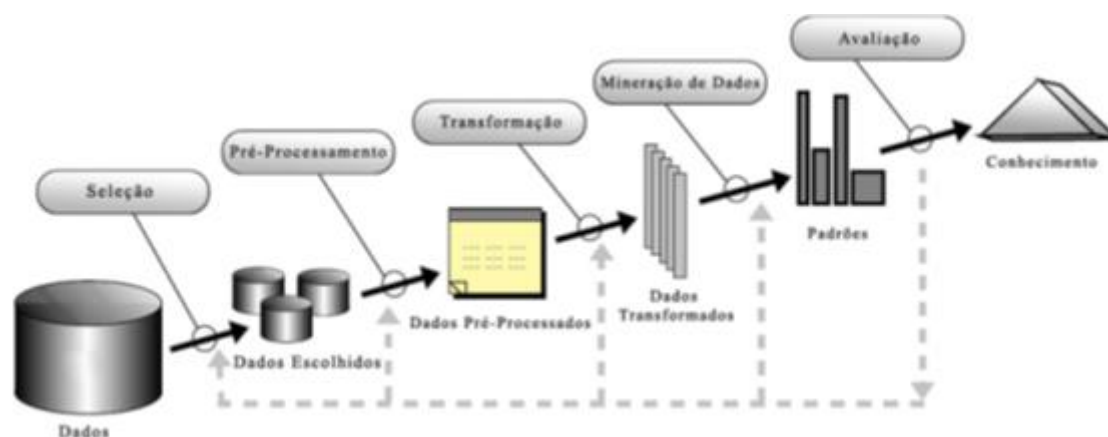


Figura 1. Figura representando o processo de KDD (FAYYAD, 1996)

Nesse sentido, a Mineração de Dados pode ser conceituada como a exploração e a análise, por meio automático ou semiautomático, de grandes quantidades de dados, a fim de descobrir padrões e regras significativos (BERRY; LINOFF, 1997). De uma forma mais simplificada, a Mineração de dados é a extração de conhecimento de grandes volumes de dados.

## 2.3. Metodologia de Discretização dos Dados e Avaliação dos Participantes do ENEM

Esta seção apresenta as regras e os parâmetros definidos para realizar a mineração na base de dados do ENEM, referente ao ano de 2014. Considera-se o aluno aprovado,

neste trabalho, quando há conformidade do candidato com as regras que permitem emitir certificado do ensino médio por meio da prova do ENEM. Os requisitos necessários para aprovação são: notas das provas de Ciências da Natureza, Ciências Humanas, Linguagens e Códigos, Matemática serem maiores ou iguais a 450 e a Nota da Redação maior ou igual a 500 pontos. Neste trabalho foi desconsiderada a necessidade de o candidato possuir idade maior ou igual a 18 anos, para poder solicitar certificado de aprovação do Ensino Médio, por meio do ENEM.

Dessa forma, os participantes que condizem com as regras dispostas anteriormente, são considerados aprovados ou marcados com bom desempenho. Entretanto, os que não condizem com essas métricas são considerados reprovados ou marcados com mau desempenho. Sendo assim, cria-se o atributo CERTIFICADO\_EMITIDO, validando a regra.

Nesse contexto, também, observa-se que a classe social foi definida conforme a renda mensal familiar, que originalmente possuía 17 possíveis valores. Conforme Massa (2014), a classe social pode ser definida por meio da renda familiar mensal, e dividida ou discretizada em 5 possíveis classes sociais, que podem ser visualizadas na Tabela 1, levando em consideração o salário mínimo vigente no ano de 2016.

**Tabela 1. Classes Sociais conforme a Renda Familiar Mensal**

<b>Classe</b>	<b>Salários mínimos (sm)</b>	<b>Renda familiar (R\$)</b>
A	Acima de 20 sm	R\$ 14.480,01 ou mais
B	10 a 20 sm	De R\$ 7.240,01 a R\$ 14.480,00
C	4 a 10 sm	De R\$ 2.896,01 a R\$ 7.240,00
D	2 a 4 sm	De R\$ 1.448,01 a R\$ 2.896,00
E	Até 2 sm	Até R\$ 1.448,00

Fonte: Adaptado de Massa (2014)

### 3. SOLUÇÃO DESENVOLVIDA

A solução aqui apresentada envolve a comparação entre os padrões encontrados a partir da mineração de dados da prova do ENEM de 2014 com o restante dos dados, utilizando consultas SQL na base de dados aberta, disponível em <http://dados.gov.br/dataset/microdados-do-exame-nacional-do-ensino-medio-enem>.

### 3.1. Mineração de Dados

Destaca-se que, antes da mineração de dados, inicialmente, os dados foram discretizados, conforme parâmetros discutidos na seção 2.3. Após, utilizaram-se alguns algoritmos de classificação do *software* WEKA 3.8.0 (disponível em: <<https://www.cs.waikato.ac.nz/~ml/index.html>>) sendo que, o algoritmo de classificação J48 obteve a maior acurácia. Assim, obteve-se a árvore de decisão utilizada para fins de comparação neste trabalho.

Observa-se que, os dados foram discretizados de forma que permitissem melhor desempenho com o classificador J48, visto que quanto mais atributos numéricos, maior a aleatoriedade dos dados, prejudicando a mineração com algoritmos de classificação. Assim, conforme descrito na seção 2.3, foram discretizados os campos de renda familiar mensal, além de ser criado o atributo CERTIFICADO\_EMITIDO. Na tabela 2 pode-se visualizar os atributos utilizados na mineração de dados, bem como os possíveis valores para os atributos não numéricos.

**Tabela 2. Atributos Selecionados e Transformados Para Mineração de Dados**

Atributos	Valores
TP_SEXO	{M, F}
IDADE	Numérico
CERTIFICADO_EMITIDO	{Sim, Não}
ID_DEPENDENCIA_ADM_ESC	{Federal, Estadual, Privada, Municipal}
TP_ESCOLA	{Pública, Privada}
ID_LOCALIZACAO_ESC	{Urbana, Rural}
IN_TP_ENSINO	{Ensino_Regular, Ensino_de_Jovens_e_Adultos, Ensino_Especial}
CLASSE_SOCIAL_RENDA_MENSAL	{A, B, C, D, E}

Fonte: Os autores, 2018

Desenvolveu-se, então, um *script* em SQL para realizar a consulta dos dados para mineração. Neste *script* foram incluídas condições que impedissem o retorno de instâncias com atributos sem valor ou com valores nulos. Após a execução do *script* no SAS *University Edition*, foi gerada uma tabela temporária com os resultados da consulta, que foi exportada, também por meio do SAS, para o formato CSV (*Comma Separated Values*), para utilização no *software* de mineração de dados WEKA.

### 3.2. Consultas SQL

Nesse trabalho foram utilizadas consultas em SQL, para verificar os padrões encontrados na árvore de decisão, comparando com toda a base de dados (excetuando-se, os registros com valores faltantes nos campos utilizados em cada consulta específica).

Nas consultas em SQL foram verificados os alunos aprovados e reprovados no ENEM, utilizando-se a função COUNT, que retorna a contagem de registros que correspondem à dependência da escola do participante, que pode ser Federal, Municipal, Estadual ou Privada.

Nessa perspectiva, após as consultas dos aprovados e reprovados de cada dependência, realizou-se uma consulta para verificar a contagem total de registros de cada dependência, como forma de validação. A Figura 2 apresenta um exemplo de uma das consultas utilizadas neste trabalho.

```

PROC SQL;
CREATE TABLE WORK.APROVADOS_FEDERAL
AS
SELECT
  COUNT(*) AS APROVADOS_FEDERAL
FROM ENEM2014.DADOS_ENEM_2014 DADOS_ENEM_2014

WHERE
/* Valores em Branco ou Nulos nao devem ser considerados */
  ID_DEPENDENCIA_ADM_ESC IS NOT NULL AND
  NOTA_CN IS NOT NULL AND
  NOTA_CH IS NOT NULL AND
  NOTA_LC IS NOT NULL AND
  NOTA_MT IS NOT NULL AND
  NU_NOTA_REDACAO IS NOT NULL AND

  ID_DEPENDENCIA_ADM_ESC LIKE "1" AND
  NU_NOTA_REDACAO >=500 AND
  NOTA_CN >= 450 AND
  NOTA_CH >= 450 AND
  NOTA_LC >= 450 AND
  NOTA_MT >= 450;

QUIT;

```

**Figura 2. Consulta SQL para contar aprovados no ENEM – Escolas Federais**  
 (Fonte: Os autores, 2018)

### 3.3. Recursos e Softwares

Os principais recursos utilizados na manipulação e obtenção das informações foram o SAS *University Edition*, para importação, transformações, execução de consultas em SQL e exportação dos dados; o *VirtualBox*, para execução da máquina virtual com o SAS, possibilitando acesso via navegador *web Mozilla Firefox*; além do *software WEKA* e o seu algoritmo J48, utilizado para mineração de dados neste trabalho.

#### 4. Resultados

Por meio da árvore de decisão, gerada pelo algoritmo de mineração J48, obteve-se os seguintes padrões sobre os participantes do ENEM de 2014 (de acordo com a dependência administrativa das escolas):

- Federal, que realizaram o ensino médio, por meio de ensino regular ou ensino especial: tendem a ter bom desempenho no exame;
- Federal, que realizaram o ensino médio, por meio de ensino de jovens e adultos: tendem a ter mau desempenho no exame;
- Estadual, das classes sociais A, B, C e D: tendem a ter um desempenho ruim, assim como os participantes da classe social E, que realizaram o ensino de nível médio em escola localizada na zona rural. O mesmo desempenho negativo, tende a ocorrer com participantes da classe social E que realizaram o ensino de nível médio em escola localizada na zona urbana, com idade menor ou igual a 18 anos, ou com idade maior que 18 e do sexo masculino;
- Estadual, da classe social E, que realizaram o ensino de nível médio em escola localizada na zona urbana, com idade maior que 18 anos, do sexo feminino, que realizaram ensino regular ou ensino de jovens e adultos: tendem a desempenho ruim, assim como os participantes que realizaram ensino especial, com idade menor ou igual a 35 anos;
- Estadual, da classe social E, que realizaram o ensino de nível médio em escola localizada na zona urbana, do sexo feminino, que realizaram ensino especial, com idade maior a 35 anos: tendem a ter bom desempenho no exame;
- Privada, das classes sociais D e E: tendem a ter desempenho ruim;
- Privada, das classes sociais A e B: tendem a ter bom desempenho;
- Privada, da classe social C, que realizaram ensino especial: tendem a ter desempenho bom, assim como os participantes que realizaram ensino regular, do sexo feminino;
- Privada, da classe social C, que realizaram ensino regular, do sexo masculino: tendem a ter desempenho ruim;
- Municipal, que realizaram ensino de jovens e adultos ou ensino especial: tendem a ter um mau desempenho;
- Municipal, que realizaram ensino regular, das classes sociais B e C: tendem a ter bom desempenho, assim como os da classe social D, do sexo feminino;
- Municipal, que realizaram ensino regular, das classes sociais A e E: tendem a ter um mau desempenho, assim como os da classe social D, do sexo masculino.

Nessa perspectiva, a utilização de consultas em SQL sobre os dados, resultou nas seguintes informações descritas, que podem ser analisadas na Tabela 3:

- Participantes, provenientes de escolas com administração Federal ou Privada, possuem taxa de aprovação acima de 50%, sendo, respectivamente 68% e 54% aprovados;
- Participantes que cursaram ou estão cursando o Ensino Médio em escolas com dependência administrativa Estadual ou Municipal, em contrapartida,



possuem taxa de aprovação inferior a 30%, possuindo, respectivamente 19% e 28% aprovados.

**Tabela 3. Aprovados e reprovados agrupados por dependência administrativa da escola**

<b>Dependência da escola</b>	<b>Aprovados</b>	<b>Reprovados</b>	<b>Total</b>	<b>Porcentagem de aprovados</b>
Federal	20.258	9.175	29.433	68,83%
Estadual	206.935	834.022	1.040.957	19,88%
Municipal	3.980	9.789	13.769	28,91%
Privada	186.186	155.824	342.010	54,44%

Fonte: Os autores, 2018

## 5. Trabalhos Relacionados

Esta seção apresenta alguns trabalhos relacionados ao trabalho apresentado. O trabalho de Gomes (2015) apresenta a utilização da mineração de dados sobre quatro bases de dados, obtidas por meio dos Microdados do ENEM dos anos de 2013 e 2014, considerando a região Nordeste do Brasil e o Estado de Pernambuco. Os resultados indicam uma forte relação entre o quesito de renda familiar e o desempenho dos candidatos, sobretudo dos alunos provenientes de escolas públicas. Ainda, a correlação entre sexo e desempenho na prova, indicou que participantes do sexo feminino possuem desempenho variante entre nota mínima e nota média. Os padrões das redações zeradas, indicaram que os participantes das classes A, B e C possuem tendência a entregar redações em branco. Já os participantes das classes D e E estão propícios a entregar redações com fuga do tema. Além disso, o fator de escolaridade dos pais não demonstra influência no desempenho dos participantes na prova de redação.

Nesse sentido, o trabalho de Gomes (2015) relaciona-se com o presente trabalho, visto que este trabalho também utiliza técnicas de mineração para tentar encontrar padrões. Ressalta-se, no entanto, que o presente trabalho analisa apenas os Microdados do ENEM de 2014, enquanto Gomes (2015) utiliza os Microdados dos anos de 2013 e 2014, além de considerar apenas os dados de algumas regiões do Brasil.

O trabalho desenvolvido por Spalenza et. al. (2016), apresenta uma ferramenta para extração de dados educacionais em Ambientes Virtuais de Aprendizagem, estabelecendo a utilização de um modelo para a adaptação de plataformas de ensino para recuperação das atividades realizadas pelos alunos. O artigo teve como AVA o *Moodle*, pois, segundo os autores, a sua organização de banco de dados, a sua estabilidade das versões, documentação clara e a facilidade de integração foram fundamentais para os resultados. O resultado apresentou uma oportunidade de



compreender melhor a produção acadêmica sobre os resultados apresentados pelas técnicas de EDM (*Educational Data Mining*). Para mostrar a robustez da proposta e a implementação, o *software* desenvolvido foi testado durante um ano e avaliado segundo a transferência de 8553 submissões de alunos. O teste realizado mostrou que a ferramenta pode ser empregada pelas técnicas de EDM para plataformas de ensino sem limitação na transferência de dados.

Diferentemente do trabalho aqui apresentado, Spalenza et al. (2016) mostram a coleta e, também, resultados da utilização dessa plataforma. Já neste artigo, a principal proposta foi a de utilizar apenas os Microdados do ENEM 2014 e encontrar diferentes padrões, com a mineração de dados abertos, além de, ser de todo o Brasil e não apenas em uma instituição específica.

Outro trabalho pertinente ao assunto é o desenvolvido por Manhães et al. (2011) da Universidade Federal Rural do Rio de Janeiro (UFRRJ), que aborda técnicas de mineração de dados para prever o risco de evasão nos cursos de graduação. A evasão no ensino superior se trata de um problema generalizado e, algumas vezes, ocorre em níveis alarmantes, prejudicando não somente o país mas, também, alunos e instituições de ensino.

Verifica-se, ainda conforme Manhães et al. (2011) que, as condições que motivam a evasão escolar são classificadas sob três agrupamentos: i) econômica - impossibilidade de permanecer no curso por questões socioeconômicas; ii) vocacional – o aluno não se identifica com o curso; iii) institucional – abandono por fracasso nas disciplinas iniciais, deficiências prévias de conteúdos anteriores, inadequação aos métodos de estudo, dificuldades de relacionamento com colegas ou com membros da instituição.

Manhães et al. (2011) também ressaltam que, a precisão dos algoritmos de mineração empregados ficou em torno de 75% a 80%. No entanto, alguns algoritmos apresentaram uma taxa elevada de falsos positivos, isto é, classificaram um aluno com risco de evasão como sem risco, um erro grave para o experimento.

Nesse contexto, o trabalho de Manhães et al. (2011) apresenta uma análise comparativa de desempenho de 10 algoritmos de mineração da ferramenta WEKA. Dentre eles está o J48, que demonstrou uma precisão elevada, de 80,21%, apesar de apresentar uma taxa de falsos positivos superior à média. A proposta relaciona-se com este trabalho, visto que utiliza técnicas de mineração de dados para encontrar padrões nos dados, mas com foco em padrões que levam à evasão.

## 6. Considerações Finais

Por meio deste trabalho, observou-se que a tentativa de encontrar diferentes padrões por meio de técnicas de mineração de dados foi relevante, já que se identificaram diferentes combinações possíveis de resultados, com base na árvore de decisão gerada pelo algoritmo de mineração J48.

Observou-se também que, utilizando as técnicas de mineração de dados, neste caso em especial a classificação, foi possível obter padrões relacionados ao desempenho alcançado pelos estudantes no ENEM. Cada padrão descoberto foi utilizado como forma

de caracterizar e/ou definir um grupo de estudantes com dados semelhantes, sendo possível prever o desempenho destes.

O modelo gerado pelo algoritmo de mineração J48 da ferramenta WEKA conseguiu classificar corretamente o desempenho de 87% dos alunos pertencentes à amostra utilizada no trabalho, que participaram do ENEM 2014, que contém os dados sem informações faltantes.

Este trabalho oferece possibilidade de continuidade desse estudo, sendo possível aplicar o modelo gerado em dados de outros anos de realização do ENEM e, assim, estabelecer parâmetros para confirmação da eficácia do modelo, além de verificar, por meio de consultas em SQL, os novos padrões descobertos com as técnicas de mineração de dados.

## Referências

- BERRY, M. J. A.; LINOFF, G. (1997). *Data Mining Techniques for Marketing, Sales and Customer Support*. Wiley Computer Publishing.
- BRASIL (2011). *Lei 12.527* de 18 de novembro de 2011. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2011/lei/112527.htm](http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/112527.htm)>. Acesso em abril, 2018.
- CHIGNARD, S. (2013). A Brief History of Open Data. *Paris Innovation Review*. Disponível em: <<http://parisinnovationreview.com/articles-en/a-brief-history-of-open-data>>. Acesso em abril, 2018.
- ENEM (2018). ENEM – *Exame Nacional do Ensino Médio*. Disponível em: <<https://enem.inep.gov.br>>. Acesso em março, 2018.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. (1996). From Data Mining to Knowledge Discovery in Data Base". *American Association for Artificial Intelligence*. Disponível em: <<https://www.aaai.org/ojs/index.php/aimagazine/article/view/1230>>. Acesso em abril, 2018.
- GOLDSCHMIDT, R.; PASSOS, E. (2005). *Data Mining: um guia prático, conceitos, técnicas, ferramentas, orientações e aplicações*. São Paulo: Elsevier.
- GOMES, T. C. S. (2015). *Descoberta de Conhecimento utilizando Mineração de Dados Educacionais Abertos*. Universidade Federal de Pernambuco, Recife. Disponível em: <<http://200.17.137.109:8081/novobsi/bsi-na-ufpe-recife/trabalhos-de-conclusao-de-curso/2015-2/Descoberta%20de%20conhecimento%20usando%20mineracao%20de%20dados%20educacionais%20abertos.pdf>>. Acesso em março, 2018.
- MANHÃES, L. M. B.; CRUZ, S. M. S.; COSTA, R. M.; ZAVALETA, J.; ZIMBRÃO, G. (2011). Previsão de Estudantes com Risco de Evasão utilizando Técnicas de Mineração de Dados. In: *Simpósio Brasileiro de Informática na Educação*. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1585>>. Acesso em março, 2018.

- MASSA, D. (2014). Faixas Salariais x Classe Social. Disponível em: <<https://domingosmassa.wordpress.com/2014/09/11/faixas-salariais-x-classe-social-qual-a-sua-classe-social/>>. Acesso em março, 2018.
- OBAMA, B. (2008). *Transparency and Open Government*. Washington, United States of America: The White House.
- OPEN DEFINITION (2014). *The Open Definition*. Disponível em: <<https://opendefinition.org/od/2.1/en/>>. Acesso em março, 2018.
- SAS (2018). *SAS University Edition: Free Statistical Software*. Disponível em: <[https://www.sas.com/en\\_us/software/university-edition.html](https://www.sas.com/en_us/software/university-edition.html)>. Acesso em março, 2018.
- SPALENZA, M. A.; NOGUEIRA, M. A.; ANDRADE, L. B., OLIVEIRA, E. (2016) Uma Ferramenta para Mineração de Dados Educacionais: extração de informação em Ambientes Virtuais de Aprendizagem. *Computer on the Beach*. Disponível em: <<https://siaiap32.univali.br/seer/index.php/acotb/article/view/12835>>. Acesso em abril, 2018.