

Análise de aprendizagem preditiva – *Revisão Sistemática*

Lucinéia Barbosa da Costa Chagas¹, Márcia Gonçalves de Oliveira²

¹Universidade Federal do Espírito Santo (UFES) – Avenida *Fernando Ferrari*, 514 – Goiabeiras, Vitória – ES - Brasil

²Centro de Referência em Formação e EaD (Cefor/IFES) – Rua *Barão de Mauá*, 30 – Jucutuquara – Vitória – ES – Brasil

cliklucineia@gmail.com, clickmarcia@gmail.com

***Abstract.** The performance prediction based on historical learning is an important process in aid of effective monitoring of learning. In order to promote a better understanding of the topic to be addressed, this article presents the results of a systematic review of studies on forecasting performance. This review included the analysis of articles published in national and international journals in order to investigate the feasibility of the information collected in the process of predicting performance of students based on their historical learning as a way to support the making proactive decisions.*

Resumo. A previsão de desempenhos baseada em históricos de aprendizagem é um processo relevante no auxílio do acompanhamento efetivo da aprendizagem. No intuito de promover um melhor entendimento sobre esse tema, este artigo traz os resultados de uma revisão sistemática de estudos sobre previsão de desempenhos. Esta revisão contou com a análise de artigos publicados em periódicos nacionais e internacionais com o objetivo de investigar a viabilidade das informações coletadas no processo de prever desempenhos de estudantes a partir de seus históricos de aprendizagem como forma de apoiar a tomada de decisões proativas.

1. Introdução

A previsão de desempenho de alunos é uma das mais antigas e populares aplicações de Mineração de Dados Educacionais por possuir uma vasta aplicabilidade, que vai desde a predição de desempenho acadêmico até a previsão da quantidade de erros que um estudante irá cometer em um determinado teste (Romero & Ventura, 2010).

Extrair informações relevantes que auxiliem a gestão da aprendizagem e viabilizem o acompanhamento efetivo de estudantes em cursos mediados por tecnologia tem sido um desafio (Rodrigues, *et alli* 2013).

Para Gottardo, *et alli* (2013), o uso dos ambientes computacionais no auxílio às atividades educacionais tem permitido a criação de vastas bases de dados nas quais armazenam-se registros detalhados sobre o processo de ensino e de aprendizagem.

Todavia, apesar do grande número de registros armazenados, observam-se algumas dificuldades dos professores na extração dessas informações para sua prática diária.

De acordo com Romero-Zaldivar *et alli* (2012), o impacto dessa limitação pode ser considerado relevante tendo em vista que um aspecto importante para a efetividade de experiências de ensino é a capacidade dos professores de monitorar o processo de aprendizagem e tomar decisões com base em eventos observados.

Nos últimos anos, muitos pesquisadores têm focado suas pesquisas no desenvolvimento de modelos e ferramentas tecnológicas no intuito de auxiliar o acompanhamento dos estudantes em ambientes computacionais.

Atualmente a Análise de Aprendizagem tem despertado interesse em como os dados de interações de estudantes podem promover êxitos no processo de ensino e de aprendizagem. Dessa forma, relacionando os dados em informações, a Análise de Aprendizagem busca, a partir destas, combinar um histórico de estados de aprendizagem de um estudante mapeados em desempenhos de atividades com seu atual estado de aprendizagem na tentativa de prever o que será útil para esse estudante no futuro (Lias, 2011].

Destacando as possibilidades e tendências da Análise de Aprendizagem, o trabalho de Oliveira (2016) apresenta uma revisão do estado da arte de tecnologias de Análise de Aprendizagem Preditiva aplicadas ao domínio de aprendizagem da programação de computadores. Além disso, Oliveira (2016) propõe um *framework* de previsão de desempenhos, em uma perspectiva multidimensional da avaliação, a partir de históricos de desempenhos em atividades de programação.

Entretanto, embora vários modelos e ferramentas computacionais de análise de aprendizagem já tenham sido desenvolvidos, ainda há ainda carência de estratégias de previsões que contemplem históricos de aprendizagem e a partir deles antecipem-se a um futuro de fracasso escolar reorientando o processo de aprendizagem de estudantes.

No intuito de promover um melhor entendimento sobre previsão de desempenhos, este trabalho apresenta uma revisão sistemática sobre a Análise de Aprendizagem Preditiva com os objetivos de analisar e discutir os resultados apresentados nos trabalhos desenvolvidos.

Este artigo está organizado conforme a ordem a seguir. A Seção 2 apresenta os materiais e os métodos utilizados nesta revisão sistemática. A Seção 3 informa os resultados obtidos. A Seção 4 destaca as discussões e contribuições. Por fim, a Seção 5 conclui este trabalho com as considerações finais e os trabalhos futuros.

2. Materiais e Métodos

Para a realização desta revisão sistemática, foram desenvolvidas pesquisas de artigos científicos sobre previsão de desempenhos de aprendizagem indexados nas bases de dados do *Portal de Periódicos da Capes*¹. Para busca, foram usadas as seguintes palavras-chave: *Desempenho, aprendizagem, previsão de desempenho, performance, learning, performance prediction*.

¹ Portal de Periódicos da Capes: <http://www.periodicos.capes.gov.br/>

Outra estratégia utilizada para complementar as pesquisas se deu na busca manual de listas de referências dos artigos selecionados. Após a coleta do material, fez-se uma análise dos títulos e resumos dos artigos selecionados. Em seguida, estes foram incluídos nos estudos sobre a Previsão de desempenhos baseados em históricos de aprendizagem publicados entre os anos de 2010 a 2016.

Os artigos que possuíam títulos e resumos não esclarecedores eram lidos na íntegra para que estudos relevantes não fossem excluídos da revisão. As pesquisas foram conduzidas em março de 2016, seguindo os critérios de inclusão e exclusão. Os critérios pré-estabelecidos para inclusão e exclusão de artigos foram escolhidos com o objetivo de responder à questão central da revisão sistemática: *Como é realizada a previsão de desempenhos baseada em históricos de aprendizagem?*

Nesse propósito, a inclusão de artigos considerou todo artigo completo nacional e internacional com abordagem focada na previsão de desempenhos de aprendizagem, além de seguir os critérios de inclusão e exclusão apresentados na Tabela 01.

Tabela 01- Critério de Inclusão e Exclusão de artigos

Inclusão de artigos	Exclusão de artigos
Artigos completos sobre previsão de desempenhos na aprendizagem.	Artigos completos sem abordagem na previsão de desempenhos na aprendizagem.
Artigos que sejam publicados entre 2010 e 2016.	Artigos que não sejam publicados entre 2010 e 2016.
Artigos com focos educacionais.	Artigos sobre previsão de desempenhos que não sejam no campo educacional.
	Artigos dos resumidos.

Após a aplicação dos critérios de inclusão e exclusão de artigos, fez-se uma análise descritiva dos dados extraídos dos estudos selecionados, como: autor, ano de publicação, país em que foi realizada a pesquisa, objetivos, instituição de ensino, técnicas e tecnologias utilizadas, periódico/congresso e principais resultados alcançados.

Em seguida, utilizou-se a seguinte questão central de pesquisa: *Como é realizada a previsão de desempenhos baseada em históricos de aprendizagem.*

Para responder a essa questão, foram definidas algumas questões específicas, conforme a Tabela 02.

Tabela 02 – Questões de Pesquisa

Questões de Investigação	Principal Objetivo
Q1- Qual a técnica utilizada na previsão de desempenhos?	Levantar as técnicas utilizadas na previsão de desempenhos.
Q2- Quais tecnologias foram contempladas com as técnicas utilizadas?	Apresentar as tecnologias utilizadas juntamente com as técnicas de previsão de desempenhos.
Q3- Que resultados foram observados neste artigo?	Analisar os resultados obtidos nas pesquisas.
Q4- Quais os principais objetivos do artigo?	Entender os objetivos propostos pelos autores do trabalho.
Q5- Qual o congresso ou periódico o artigo foi publicado?	Conhecer os congressos/periódicos em que os trabalhos foram publicados.

As questões de pesquisas apontadas na Tabela 02 foram orquestradas no intuito de buscar os principais pontos que influenciaram a aprendizagem através da previsão de desempenhos, além de responder à questão central desta pesquisa.

O principal objetivo deste artigo é apresentar os principais resultados obtidos nesta revisão sistemática para o possível delineamento de trabalho futuros. Os resultados das questões norteadoras são apresentados na próxima seção.

3. Resultados

Com a estratégia definida, o material coletado resultou em 122 artigos, e, de acordo com os objetivos do estudo e os critérios de inclusão, apenas cinco artigos foram selecionados.

Os 117 artigos descartados investigavam previsões de desempenhos sem o foco educacional com previsões através de dados em redes sociais, avaliação de desempenho, dentre outros. De forma a tornar mais simples a leitura, os trabalhos serão listados a seguir com informações resumidas:

Uma abordagem para a previsão de desempenho de alunos de Computação em disciplinas de programação.

- *Descrição:* Método de identificação de estudantes propensos ao fracasso nas disciplinas iniciais de programação.

Previsão do desempenho de estudantes aplicando algoritmos de filtragem colaborativa baseados em fatoração de matrizes.

- *Descrição:* apresentação de algoritmos de fatoração de matrizes que preveem se um estudante acerta ou erra uma questão considerando o seu perfil e os demais perfis de estudantes.

MOOC Performance Prediction via Clickstream Data and Social Learning Networks.

- *Descrição:* Estudo de previsão de desempenho do estudante em Cursos *Online (MOOCs)*, no qual tem por objetivo prever se um estudante acerta a resposta correta na primeira tentativa.

Personalized Forecasting Student Performance

- *Descrição:* Este trabalho propõe uma nova abordagem de previsão personalizada. Em vez de utilizar todos os dados históricos, os métodos propostos utilizam apenas as informações individuais dos alunos para a previsão de seus desempenhos.

Student Performance Prediction using Machine Learning.

- *Descrição:* Neste trabalho, é proposto um modelo de previsão de desempenhos utilizando Redes Neurais.

A Tabela 03 na página a seguir apresenta um resumo dos estudos incluídos nesta revisão sistemática.

Tabela 03 – Características dos estudos selecionados

Artigo	Autor(es)/ Ano	Instituição De Ensino	Congresso/ Periódico	Principais objetivos	Técnica usada	Tecnologias usadas	Resultados alcançados
Uma abordagem para a previsão de desempenho de alunos de Computação em disciplinas de programação.	T. A. Pascoal, D. M. Brito, T. G. Rêgo / 2015.	Universidade Federal da Paraíba	<i>TISE</i>	Propor um modelo para identificar, precocemente, alunos propensos ao insucesso nas disciplinas de programação.	<i>Algoritmo IBk, RandomForest (RF), BayesNET (BNet) e MultilayerPerceptron (MLP).</i>	<i>Pentaho, PostgreSQL e Weka.</i>	Os classificadores produziram bons resultados, sempre com acurácias e taxas de <i>VP</i> e <i>VN</i> superiores a 70%. Dentre os algoritmos testados, o <i>RandomForest</i> obteve acurácia próxima a 83%, com taxas de <i>VP</i> e <i>VN</i> a 81%, porém o algoritmo que obteve melhor taxa de classificação de <i>VP</i> foi o <i>IBk</i> , com resultados superiores a 93%.
Previsão do desempenho de estudantes usando algoritmos de filtragem colaborativa baseados em fatoração de matrizes.	B. H. S. Dodorico, J. M. A. Coello / 2014	Faculdade de Engenharia de Computação, Grupo de Pesquisa em Sistemas Inteligentes.	XIX Encontro de Iniciação Científica.	Apresentar algoritmos de fatoração de matrizes que preveem se um estudante acertará ou não uma questão, a partir de seu perfil e do perfil dos demais estudantes.	Algoritmo de fatoração de matrizes.	<i>RapidMiner</i>	Como resultado o trabalho conclui que, apesar dos melhoramentos na precisão dos algoritmos de fatoração de matrizes, aquele com o melhor resultado continuou sendo a técnica clássica de filtragem colaborativa <i>User-kNN</i> .
<i>MOOC Performance Prediction via Clickstream Data and Social</i>	<i>C. G. Brinton, M. Chian / 2015</i>	<i>Department of Electrical Engineering, Princeton University</i>	<i>IEEE Xplorer Digital Library</i>	Prever se o aluno acerta a resposta correta da pergunta na primeira tentativa.	<i>Standard Algorithms in Big Data</i>	<i>Python</i>	Observou-se que o esquema proposto superou o conjunto de dados e métricas consideradas, e que a melhoria foi apresentada no início do curso. Além de ser útil para analisar os dados de fluxo de cliques o que torna

<i>Learning Networks.</i>							possível identificar os intervalos em uma maior probabilidade de acerto ou não à pergunta correspondente.
<i>Personalized Forecasting Student Performance</i>	<i>N. Thai-Nghe T. Horváth L. Schmidt-Thieme/ 2011</i>	<i>University of Hildesheim</i>	<i>IEEE Xplorer Digital Library</i>	Propor métodos de previsão personalizados, com abordagem simples e eficiente, para a previsão de desempenhos de estudantes.	<ul style="list-style-type: none"> - <i>N-PSEF (Non-biased Personalized Single Exponential smoothing Forecasting).</i> - <i>B- PDE, respectivamente (Biased Único Personalizado / Duplo Previsão suavização exponencial).</i> - <i>Method B-PDMF (Biased Personalized Discounted-Mean Forecasting).</i> - <i>State-of-the-art matrix factorization.</i> 	O artigo não apresenta a tecnologia utilizada.	Como resultados alcançados, os autores informam que os métodos de previsão personalizados tiveram resultados positivos e mais rápidos se comparados com outros métodos <i>state-of -the-art</i> em <i>PSP</i> .
<i>Student Performance Prediction using Machine Learning.</i>	<i>H. Agrawal, H. Mavani / 2015</i>	<i>Department of Information Technology, College of Engineering</i>	<i>International Journal of Engineering Research and Technology</i>	Propor um modelo para previsão de desempenhos dos alunos em uma organização acadêmica.	Redes neurais.	<i>MATLAB</i>	Como resultados alcançados, os autores afirmam que o desempenho das redes neurais aumentam proporcionalmente à medida que aumenta o tamanho do conjunto de dados e podem revelar-se ferramentas poderosas se aplicadas no ambiente escolar.

4. Discussões

Os trabalhos selecionados nesta revisão sistemática mostram heterogeneidade quanto à metodologia utilizada, o que impede a realização de uma meta-análise. Neste caso, será realizada uma apresentação descritiva dos dados.

Os estudos apresentados nessa revisão mostraram técnicas diferentes para prever desempenhos, como, por exemplo: Algoritmo *IBk*, Algoritmo de fatoração de matrizes, *Standard Algorithms in Big Data*, o *N-PSEF*, *B-PDEF*, *Method B-PDMF*, *State-of-the-art matrix factorization* e Redes Neurais.

As diferentes técnicas podem estar atribuídas aos diferentes métodos utilizados e aos diferentes objetivos de estudo. As pesquisas distinguiram-se em vários aspectos que variam desde a modalidade de ensino até a quantidade de material coletado.

Dois dos estudos abordados nesta revisão propõem modelos de previsão de desempenhos. Um deles é focado na disciplina de programação e outro não especifica a disciplina, mas informa que a previsão foi utilizada no âmbito acadêmico.

No primeiro artigo, o modelo proposto utiliza como base o fluxograma dos cursos de Computação. A situação do aluno é definida a partir de sua média final. Neste caso os alunos que obtiveram nota menor que 5.0 foram considerados como sendo de classe *Insucesso* e os alunos que alcançaram pelo menos 5.0 foram considerados da classe *Sucesso*.

Para avaliação do método foram selecionados quatro algoritmos de aprendizagem de máquina distintos: *IBk*, *RandomForest (RF)*, *BayesNET (BNet)* e *MultilayerPerceptron (MLP)*. Para cada um deles, buscou-se, por tentativa e teste, encontrar o conjunto de parâmetros que produzisse os melhores resultados.

Como forma de avaliação dos métodos, utilizou-se a métrica *Acurácia* (número de instâncias classificadas corretamente) e as taxas de *Verdadeiros Positivos (VP)* e de *Verdadeiros Negativos (VN)*. Os resultados obtidos com classificadores populares atestaram a viabilidade das previsões realizadas.

No segundo artigo, o modelo proposto levou em consideração a existência de uma relação linear entre os níveis de desempenhos acadêmicos de um aluno no passado. Essa relação pode ser expressa com a utilização da Regressão Linear Multivariada, no qual o algoritmo é treinado e testado em uma validação cruzada para previsões.

Uma vez confirmado que os dados se adaptam a um algoritmo de aprendizado de máquina, foi realizado um estudo comparativo entre redes neurais e a classificação *Bayesiana*, variando entre treinamento e teste conjuntos. Os resultados da pesquisa mostraram que redes neurais tendem a superar a classificação *bayesiana*. Outro trabalho selecionado apresenta um método de previsão de desempenhos personalizado baseado nas informações individuais dos alunos para prever seus próprios desempenhos.

O material utilizado nesta pesquisa reúne dados de históricos do estudante, além de um parâmetro para verificar o comprimento destes dados. Para a previsão personalizada dos estudantes foram utilizadas técnicas, como: *N-PSEF (Non-biased)*, *N-PDEF (Nonbiased)*, *Student-Task-Bias*, *B-PDEF (Biased Personalized Single/ Double Exponential smoothing Forecasting)* e *PMDF (Biased personalizado Descontado -Meio Forecasting)*.

As abordagens propostas foram comparadas com a técnica Original *single/double* de previsão exponencial (*SEF/DEF*) e com matriz de fatoração e de regressão logística. A partir dos experimentos, descobriu-se que a abordagem histórica é relevante, o que pode significar implicitamente, que para resolução de novos problemas, os alunos precisam de todo o conhecimento acumulado, em vez de só serem considerados os conhecimentos atuais.

De forma diferente deste trabalho, outro artigo selecionado para revisão sistemática, aborda uma análise da previsão de desempenhos com a utilização de técnicas de fatoração de matrizes. Essa análise pode ser interpretada como uma forma de buscar aprimorar a precisão e a escalabilidade dos algoritmos, levando em conta o volume de dados disponíveis e a densidade da matriz usuário-item construída.

Nesse trabalho, os algoritmos foram avaliados comparando os seus desempenhos relativos e o desempenho de um algoritmo de filtragem colaborativa baseado no *kNN*. A precisão foi avaliada por meio de métricas *RMSE* (*Root Mean Square Error*) e *MAE* (*Mean Absolute Error*), que medem a diferença entre os valores previstos e os observados.

O processo implementado consiste na execução de uma sequência de atividades. No qual a base de dados é importada para uma determinada ferramenta. Após a importação da base de dados, essa é filtrada em função do valor de um dos atributos, no qual indica se um estudante acertou ou não uma determinada questão.

Em seguida foram selecionados os atributos a serem trabalhados e definidos a identificação do usuário e do item.

Ao aplicar o algoritmo *kNN* e os algoritmos de fatoração de matrizes, observou-se que o algoritmo com menor índice de erros foi o algoritmo *User-kNN*, todavia apesar do melhor resultado de precisão, o algoritmo *User-KNN* foi aquele que requereu o maior tempo de execução.

Com base nas informações adquiridas na aplicação do algoritmo *kNN* os autores, decidiram focar o estudo no algoritmo de fatoração de matrizes *BMF* (*Biased Matrix Factorization*) para trabalhar com a manipulação de valores dos parâmetros a fim de melhorar sua precisão (Docorico & Coelho, 2014).

Com o uso deste algoritmo foi possível uma leve melhora da precisão, sem um aumento expressivo do tempo de execução como os outros parâmetros. Porém, apesar da melhora na precisão dos algoritmos de fatoração de matrizes, aquele com o melhor resultado continuou sendo a técnica clássica de filtragem colaborativa *User-kNN*.

O último artigo abordado nessa discussão mostra o uso de previsões via *clickstream*. Esses métodos são projetados para determinar os intervalos a partir de dados e usar estimativas correspondentes nos algoritmos de previsão.

Foram aplicados alguns algoritmos padrões para previsão em *CFA*, como: *Sec. IV-B, Standard Algorithms in Big Data, Matrix Factorization (MF), K Nearest Neighbor (KNN)*. As avaliações consideraram um tipo de comportamento dos alunos para ver como algoritmos padrões poderiam melhorar a previsão de aumento do desempenho (Brinton & Chian, 2015).

Observou-se nessa pesquisa que a incorporação de algoritmos padrões trouxe benefícios para a detecção mais rápida dos intervalos. A razão para tal é que há poucas

entradas para cada indivíduo, além dos algoritmos de fluxo de *cliques* possuir indicadores e alavancar os dados de observação agregados a todos os usuários (Brinton & Chian, 2015).

Através de avaliações, observou-se que o método proposto trouxe melhoras já no início do curso. Além de ser útil para analisar os dados de fluxo de cliques em quantidades, o que tornou possível identificar intervalos de identidade.

Uma das razões do interesse em se estudar a análise preditiva de aprendizagem decorre da elevada prevalência das dificuldades apresentadas na previsão de desempenhos no ambiente acadêmico para antecipar-se a um futuro de fracasso escolar e reorientar um processo de ensino e de aprendizagem.

Dessa forma, a realização de estudos cuidadosamente desenhados, com uso de técnicas de previsão de desempenho, pode contribuir para a produção de novas formas de êxto no processo de ensino e de aprendizagem.

5. Considerações finais e trabalhos futuros

Este artigo apresentou uma Revisão Sistemática sobre análise de previsão de aprendizagem. A revisão contou 122 artigos coletados, nos quais apenas cinco foram incluídos. Os demais 117 artigos foram descartados por não enquadrar nas regras de inclusão da revisão.

Os resultados mostram que os pesquisadores estão desenvolvendo pesquisas no intuito de confirmar ou propor métodos para prever o desempenho de estudantes com o propósito de melhorar a qualidade das previsões de desempenho já existentes.

Como trabalhos futuros destacamos a expansão desta revisão sistemática englobando novos estudos relacionados à previsão de desempenho e ao desenvolvimento de uma revisão sistemática sobre previsões de desempenho com foco na aprendizagem de programação.

6. Referências

- Agrawal, H. ; Mavani, H. *In Student Performance Prediction using Machine Learning. International Journal of Engineering Research and Technology*, 2015.
- Brinton, C. G.; . Chian, M.: *In MOOC Performance Prediction via Clickstream Data and Social Learning Networks. IEEE Xplorer Digital Library*, 2015.
- Dodorico, B. H. S. ; Coello, J. M. A. In: *Previsão do desempenho de estudantes usando algoritmos de filtragem colaborativa baseados em fatoração de matrizes*. Anais do XIX Encontro de Iniciação Científica, 2014.
- Gottardo, E.; Kaestner, C.; Noronha, R. V. *Aplicação de Técnicas de Mineração de Dados para Estimativa de Desempenho Acadêmico de Estudantes em um AVA Utilizando Dados com Classes Desbalanceadas*. In: ICBL2013 – International Conference on Interactive Computer aided Blended Learning.
- Lias, Tanya E.; Elias, Tanya. *Learning Analytics: The Definitions, the Processes, and the Potential*. 2011.

- Oliveira, M.G. (2016). *As Tecnologias de Análise de Aprendizagem e os Desafios de Prever Desempenhos de Estudantes de Programação*. In Workshop de Desafios da Computação Aplicada à Educação (V DesafIE!). CSBC 2016, Porto Alegre, RS. SBC.
- Pascoal, T. A. ; Brito, D. M. , Rêgo, T. G. *Uma abordagem para a previsão de desempenho de alunos de Computação em disciplinas de programação*. In: *Nuevas Ideas en Informática Educativa TISE 2015*.
- Rodrigues, L.R.; Medeiros, F. P. A.; Gomes, A. S. *Modelo de Regressão Linear aplicado à previsão de desempenho de estudantes em ambiente de aprendizagem*. In: II Congresso Brasileiro de Informática na Educação (CBIE 2013) - XXIV Simpósio Brasileiro de Informática na Educação (SBIE 2013).
- Romero, C., & Ventura, S. (2010). Educational data mining: a review of the state of the art. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 40(6), 601-618
- Romero-Zaldivar, V.A., Pardo, A., Burgos, D., Kloos, C.D. (2012). *Monitoring Student Progress Using Virtual Appliances: A Case Study*. *Computers & Education*, nº. 58, p. 1058-1067.
- Thai-Nghe, N.; Horváth, T.; Schmidt-Thieme, L.: In *Personalized Forecasting Student Performance - IEEE Xplorer Digital Library*, 2011.