

| |
|--|
| Universidade de Pernambuco Programa de Pós-Graduação em Engenharia da Computação (PPGEC) |
| Proposta de Dissertação de Mestrado |
| Área: Inteligência Computacional |
| Título: Análise de Trajetórias Acadêmicas com Ênfase no Estágio Obrigatório via Clusterização Temporal. |
| Orientador – Alexandre Magno Andrade Maciel (amam@ecomp.poli.br) |
| Descrição <p>A análise de dados educacionais tem se destacado como ferramenta estratégica no ensino superior, permitindo compreender fatores que impactam o desempenho acadêmico, identificar padrões de progresso e orientar ações institucionais mais eficazes [1][2]. A identificação de perfis estudantis e de eventos que influenciam as trajetórias acadêmicas é fundamental para mitigar riscos de evasão e apoiar a gestão acadêmica.</p> <p>Técnicas de <i>Educational Data Mining</i> (EDM) e <i>Machine Learning</i> (ML) vêm sendo aplicadas para extrair conhecimento a partir de grandes volumes de dados institucionais. Métodos como <i>clustering</i>, seleção de atributos e análise de séries temporais permitem agrupar estudantes com comportamentos semelhantes e identificar variáveis com maior impacto no desempenho acadêmico [3][4]. Esses modelos oferecem suporte na detecção de padrões ocultos, na compreensão das dinâmicas acadêmicas e no desenvolvimento de estratégias mais assertivas.</p> <p>Apesar dos avanços, ainda existem desafios como a construção de indicadores educacionais robustos, a escolha eficiente de atributos relevantes e o desenvolvimento de modelos interpretáveis para gestores. A análise de séries temporais surge como abordagem promissora para compreender a evolução do desempenho dos estudantes, permitindo analisar padrões ao longo dos semestres, especialmente em eventos acadêmicos críticos.</p> <p>Este projeto propõe desenvolver modelos computacionais capazes de analisar trajetórias acadêmicas, identificar padrões de comportamento e avaliar impactos de eventos específicos, como a realização de estágios obrigatórios. Serão empregadas técnicas de <i>clustering</i>, seleção de atributos e análise temporal multivariada, visando gerar diagnósticos que apoiem a gestão acadêmica na definição de intervenções e políticas voltadas ao sucesso e à permanência dos estudantes.</p> |
| Referências Bibliográficas [1] Baker, R.S., Inventado, P.S. (2014). Educational Data Mining and Learning Analytics . In: Larusson, J., White, B. (eds) Learning Analytics. Springer, New York, NY. [2] Dekker, G. W., Pechenizkiy, M.; Vleeshouwers, J. M. (2009). Predicting Students Drop Out: A Case Study . In Proceedings of the 2nd International Conference on Educational Data Mining. [3] Macfadyen, L. P.; Dawson, S. (2010). Mining LMS Data to Develop an “Early Warning System” for Educators: A Proof of Concept . Computers & Education, 54(2), 588-599. [4] Romero, C.; Ventura, S. (2010). Educational Data Mining: A Review of the State of the Art . IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), vol. 40, no. 6, pp. 601-618. |