



ANÁLISE DO GANHO DE APRENDIZADO NO ENSINO DE FÍSICA COM TÉCNICAS DE APRENDIZADO DE MÁQUINA

Palavras-Chave: Aprendizado de máquina, ensino de Física, leis de Newton

GABRIEL HENRIQUE PASTORELO MOREIRA [IFGW/UNICAMP]

Prof. Dr. RICKSON COELHO MESQUITA (orientador) [IFGW/UNICAMP]

INTRODUÇÃO:

A busca por inovação no ensino não é uma novidade das últimas duas décadas. Como aponta Cuban (1986 apud CYSNEIROS, 1999), a inserção do rádio, da TV e outros aparelhos eletrônicos no ensino começou por volta de 1920. Entretanto, como lembram Teodoro e Lopes (2013, p. 92-93), o uso da tecnologia, por si só, não resulta em aprendizagem. Quando aplicada em condições favoráveis, a tecnologia apresenta resultados positivos no ensino (WADMANY, LEVIN, 2009) e, em particular, o uso de algoritmos de aprendizado de máquina tem se mostrado promissor em suas aplicações na educação (SELF, 1998). Um exemplo foi a criação de um sistema inteligente baseado em inteligência artificial para problemas de álgebra desenvolvido por Koedinger (et al., 1997) – o qual, aplicado a um grupo significativo de estudantes ($N > 100$), foi capaz de modelar o perfil do aluno de acordo com a forma que o mesmo resolvia as questões propostas, além de apontar os erros e oferecer um feedback e instruções personalizadas. Como analisado por du Boulay (1998), o grupo que utilizou o sistema teve uma performance significativamente melhor que o grupo controle, no qual o sistema não foi utilizado.

O uso de sistemas inteligentes e baseados em aprendizado de máquina se mostra ainda mais benéfico para a individualização do aprendizado (du Boulay, 1998), inserindo-se no contexto de metodologias de ensino como a aprendizagem baseada no domínio. Em seu sentido mais básico, a metodologia sugere que os alunos devam compreender um dado conceito antes que se espere deles o entendimento de outro mais avançado (CARROLL, 1963; GUSKEY, 2015). No entanto, o tempo para a compreensão de um dado conceito é diferente para cada aluno, como indicado por Carroll (1963). Uma pergunta em aberto é como técnicas de aprendizado de máquina poderiam ajudar a individualizar o aprendizado dos alunos no ensino de mecânica Newtoniana a partir da classificação do desempenho dos alunos nos diferentes estágios do aprendizado, similar ao modelo proposto por Koedinger (et al., 1997). Sendo assim, a presente proposta tem como tema central investigar esta questão.

METODOLOGIA:

Com o objetivo de explorar e investigar como o conceito de aprendizagem de máquina pode agregar ao ensino de Física em paralelo à metodologia da aprendizagem baseada no domínio, a primeira parte do projeto envolveu o desenvolvimento de um estudo dirigido sobre aprendizado de máquina, os diferentes algoritmos para classificação e a lógica envolvida em cada algoritmo.

No seguimento do projeto, buscamos implementar algoritmos de previsão e classificação para avaliar os ganhos de aprendizado a partir dos conhecimentos prévios utilizando conceitos de estatística Bayesiana. O algoritmo foi validado em dados reais, obtidos a partir de um trabalho anterior (MOREIRA, 2019). De forma breve, utilizamos respostas de 78 alunos coletadas durante um curso de extensão sobre os fundamentos do movimento. Os alunos responderam a um teste diagnóstico (conhecido como FCI) previamente validado (HESTENES, WELLS, SWACKHAMER, 1992) antes do início do curso (pré-FCI) e após a sua conclusão (pós-FCI). A comparação dos testes pré-FCI e pós-FCI permite quantificar o ganho de aprendizado dos alunos. Além disso, ao longo do curso os alunos responderam diversas questões sobre os conceitos de movimento como parte do seu aprendizado; o número de questões respondidas por aluno variou de acordo com o tempo necessário para compreender um determinado conceito.

Com esta base de dados, desenvolvemos um algoritmo para calcular a probabilidade de um aluno ter dominado os conceitos do movimento de forma iterativa (isto é, na ordem cronológica de resolução das questões). Inicialmente, a probabilidade do aluno ter aprendido, $P(D)$, é obtida a partir de um teste diagnóstico (neste caso, o pré-FCI), sendo alterada cada vez que o aluno responde a uma questão apresentada. Consideramos $P(R|D)$ a probabilidade de observarmos uma determinada resposta sendo a hipótese de o aluno ter aprendido verdadeira, e $P(R|\neg D)$ a probabilidade de observarmos uma determinada resposta sendo a hipótese de o aluno ter aprendido falsa. A cada resposta do aluno, a probabilidade do aluno ter aprendido é atualizada de acordo com a evidência dada pela resposta apresentada seguindo o teorema de Bayes:

$$P(D|R) = \frac{P(D) \cdot P(R|D)}{P(D) \cdot P(R|D) + P(\neg D) \cdot P(R|\neg D)}$$

onde $P(\neg D)$ naturalmente se define como o complementar de $P(D)$ - ou seja, $P(\neg D) = 1 - P(D)$. Para cada aluno, o resultado $P(D|R)$ obtido pelo algoritmo ao final de todas as questões catalogadas foi comparado com o pós-FCI, o qual foi utilizado como parâmetro pra dizer se o aluno aprendeu ou não de acordo com determinados critérios.

Por fim, realizada a implementação e validação do algoritmo utilizando as informações obtidas da trajetória de aprendizado dos alunos (inferida pelas questões respondidas ao longo do curso), propomos um algoritmo para um sistema de gestão de aprendizagem automático a partir de técnicas de aprendizado de máquina. O sistema proposto é capaz de individualizar o aprendizado e funcionar como ferramenta complementar ao ensino.

RESULTADOS E DISCUSSÃO:

O estudo dirigido mostrou que a grande maioria de aplicações de inteligência artificial no ensino se dá em matemática, gramática e programação, e em tópicos introdutórios para crianças e adolescentes (ABUELOUN, ABU-NASER, 2017), mas todas com um foco diferente ao que pretendemos dar em nosso projeto. Por outro lado, a ideia do rastreamento do conhecimento (*knowledge tracing*), popularizada por Corbett e Anderson (1995) (em sua variação chamada *Bayesian Knowledge Tracing*, ou BKT) e modernizada por Pardos e Heffernan (2010) (chamada de *individualized-BKT*), condiz com a nossa proposta, utilizando redes Bayesianas para prever a performance de um aluno de acordo com suas respostas em um conjunto de questões.

Inspirados por esta bibliografia e com os dados de todos os alunos e questões obtidos do projeto anterior devidamente catalogados conforme o descrito na seção Metodologia, realizamos o cálculo iterativo em ordem cronológica para todas as questões realizadas pelos alunos. A Figura 1 mostra a evolução da probabilidade de aprendizado para dois alunos arbitrários ao longo do número de questões respondidas. Do lado esquerdo, há o caso de um aluno que não aprendeu o conteúdo após responder mais de 70 questões diferentes, apesar de um bom começo, sendo um típico caso de um aluno que perde a motivação ao longo do aprendizado. Um sistema como o proposto neste projeto pode identificar isto em tempo real e, a partir daí, notificar o professor para uma intervenção precoce. Do lado direito da Figura 1 é possível notar o outro extremo: um aluno que pouco conhecia o assunto e, após 16 questões, demonstrou domínio sobre os principais conceitos acerca do movimento.

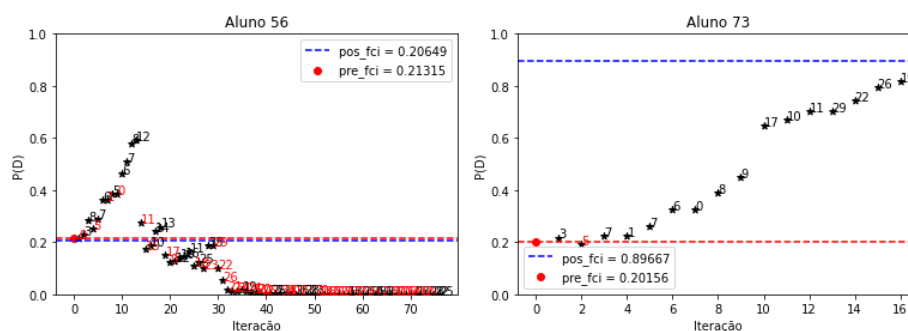


Figura 1 – Exemplos da evolução do aprendizado de dois alunos arbitrários inferidas pelo algoritmo de aprendizagem proposto neste projeto. O eixo y, $P(D)$ representa a probabilidade do aluno ter aprendido (isto é, ter atingido o domínio do aprendizado) após responder uma dada questão. As linhas tracejadas em vermelho e azul representam, respectivamente, a probabilidade inicial e final de domínio do aprendizado do aluno inferida pelo FCI.

A partir das simulações com os dados que tínhamos disponível, definimos o limiar $P(D) \geq 0,8$ para estabelecer o domínio do aprendizado. Desta forma, o resultado final obtido pelo algoritmo pode ser comparado com o resultado do pós-FCI. Utilizando os limiares do FCI estabelecidos na literatura para determinação do domínio da mecânica Newtoniana, e considerando todos os 78

alunos analisados, obtivemos uma acurácia de, aproximadamente, 86%. A tabela 1 apresenta a matriz de confusão da classificação realizada pelo algoritmo.

Tabela 1 – Matriz de confusão do algoritmo

	$P(D) \geq \text{limiar}$	$P(D) < \text{limiar}$
Dominou	20	7
Não Dominou	4	47

Com o bom resultado obtido pelo algoritmo, propomos um pseudocódigo que pode ser facilmente implementado para construir um Sistema de Gestão de Aprendizagem inteligente. De forma resumida, a proposta do sistema é: dado o $P(D)$ inicial do aluno, obtido por um teste diagnóstico prévio, disponibilizar um material de estudo e, posteriormente, verificar seu aprendizado através de questões específicas. O nível de dificuldade da questão apresentada depende do grau de conhecimento atual do aluno (aferido pelo $P(D)$). Se um aluno tiver um baixo $P(D)$, o sistema irá apresentar uma sequência de questões fáceis, de forma que, caso as acerte, o sistema aumentará o nível de dificuldade e de discriminação, a fim de dar um salto no $P(D)$ e não forçar o estudante a realizar um grande número de questões.

CONCLUSÕES:

De forma geral, este trabalho propôs a implementação de um Sistema de Gestão de Aprendizagem inteligente, capaz de individualizar o ensino de Física. O algoritmo proposto é baseado no conceito de rastreamento do conhecimento, e foi validado a partir de um conjunto de dados disponíveis para o ensino dos fundamentos do movimento. Quando aplicado neste conjunto de dados, o algoritmo conseguiu identificar os alunos que de fato aprenderam os conceitos envolvidos com uma acurácia de 86%. Com base na acurácia observada, podemos dizer que o algoritmo proposto apresentou um bom resultado na predição e classificação do aprendizado dos estudantes. Dessa forma, o algoritmo foi generalizado para um pseudocódigo que pode ser futuramente utilizado para a criação do Sistema de Gestão de Aprendizagem (SGA).

BIBLIOGRAFIA

CYSNEIROS, Paulo Gileno. **Novas tecnologias na sala de aula: melhoria do ensino ou inovação conservadora.** Informática Educativa, v. 12, n. 1, p. 11-24, 1999.

TEODORO, João Vítor; LOPES, José Marcos. **Evolução e perspectivas da tecnologia em sala de aula e na formação docente.** Educação e Fronteiras, v. 3, n. 8, p. 91-104, 2013.

WADMANY, Rivka; LEVIN, Tamar. **Changes in Instructional Practices in Technology-Enriched Classrooms and Student Views on Learning.** UCFV Research Review, v. 2, n. 3, p. 36-53, 2009.

SELF, John. **Grounded in reality: the infiltration of ai into practical educational systems.** 1998.

KOEDINGER, Kenneth R. et al. **Intelligent tutoring goes to school in the big city.** 1997.

DU BOULAY, Benedict. **What does the “AI” in AIED buy?**. 1998.

CARROLL, John B. **A model of school learning**. Teachers college record, 1963.

GUSKEY, Thomas R. **Mastery learning**. 2015.

MOREIRA, Gabriel H. P. **Validação de uma metodologia ativa para o ensino do movimento no Ensino Médio**. Projeto PIBIC, UNICAMP, cota 2019-2020.

HESTENES, David; WELLS, Malcolm; SWACKHAMER, Gregg. **Force concept inventory**. The Physics Teacher, [s.l.], v. 30, n. 3, p.141-158, mar. 1992. American Association of Physics Teachers (AAPT). <http://dx.doi.org/10.1119/1.2343497>.

ABUELOUN, Nour N.; ABU-NASER, Samy S. **Mathematics intelligent tutoring system**. 2017.

CORBETT, Albert T.; ANDERSON, John R.; O'BRIEN, Alison T. **Student modeling in the ACT programming tutor**. Cognitively diagnostic assessment, p. 19-41, 1995.

PARDOS, Zachary A.; HEFFERNAN, Neil T. **Modeling individualization in a bayesian networks implementation of knowledge tracing**. In: International Conference on User Modeling, Adaptation, and Personalization. Springer, Berlin, Heidelberg, 2010. p. 255-266.