

## Modelagem Estatística do Tempo de Permanência de Estudantes no Estado de Confusão Através de Análise de Sobrevivência Multivariada

Diógenes D'Avila Goldoni<sup>1</sup>, Helena M. Reis<sup>2</sup>, Patrícia A. Jaques<sup>2</sup>

<sup>1</sup>PPG em Computação Aplicada (PPGCA)

Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo – RS – Brasil

<sup>2</sup>PPG em Educação em Ciências, Educação Matemática e Tecnologias Educativas (PPGECEMTE)

Universidade Federal do Paraná (UFPR), Palotina – PR – Brasil

<sup>3</sup>PPG em Informática (PPGInf)

Universidade Federal do Paraná (UFPR), Curitiba – PR – Brasil

davilag@edu.unisinos.br, patricia@inf.ufpr.br, helena.macedo@ufpr.br

**Abstract.** *Emotions have a significant impact on the learning process. In particular, the academic emotion of confusion can play both a positive and a negative role during educational activities. While confusion can foster intentional deliberations about the subject at hand, a student who remains confused for extended periods of time may transition to purely negative academic emotions. This article presents the results obtained through the analysis of data obtained from 25 students who used the PAT2Math intelligent tutoring system and performed a personality test, highlighting the influence of different personality traits and previous performance in algebra on the students' permanence time in the academic emotion of confusion. Upon statistical analysis and modeling through the lens of survival analysis, it was possible to identify and model statistically significant differences in the time spent in confusion by students with distinct personality traits and previous knowledge of algebra.*

**Resumo.** *Emoções possuem um impacto significativo no processo de aprendizagem. Em especial, a emoção acadêmica da confusão pode possuir um papel tanto positivo quanto negativo durante atividades educacionais. Embora a confusão possa fomentar deliberações intencionais sobre o assunto tratado, um aluno que permanece confuso por um longo período de tempo pode vir a transacionar para emoções acadêmicas puramente negativas. Este artigo apresenta os resultados obtidos através da análise de dados obtidos de 25 alunos que fizeram uso do sistema tutor inteligente PAT2Math e realizaram um teste de personalidade, destacando a influência de diferentes traços de personalidade e desempenho anterior em álgebra no tempo de permanência dos alunos na emoção acadêmica de confusão. Através de modelagem estatística sob a ótica da análise de sobrevivência, foi possível identificar e modelar diferenças estatisticamente significativas no tempo de permanência em confusão de alunos com traços distintos de personalidade e conhecimento prévio de álgebra.*

## 1. Introdução

A matemática tende a ter uma má reputação como disciplina escolar e, desde o ensino fundamental, é percebida como uma das disciplinas mais difíceis [Zaslavsky 1994, Amato 2018]. Esse sentimento é exacerbado quando os alunos são apresentados pela primeira vez à ideia de variáveis desconhecidas nas equações, exigindo o uso de números e letras nos cálculos [Seffrin et al. 2012]. Essas percepções podem levar os alunos a sentimentos de inadequação com efeitos duradouros, como a ansiedade matemática e a síndrome do impostor, que podem perdurar por toda a vida [Zeidner 1998, Brooks 2014]. Especialistas em ensino e pesquisadores educacionais estudam e desenvolvem diferentes técnicas de tutoria para tentar ajudar os alunos, minimizando esses efeitos negativos.

Uma estratégia de ensino eficaz é a tutoria individual, que emprega uma relação um aluno por professor [Bloom 1984]. Para enfrentar a questão de custo e escala relacionada à tutoria individualizada, a área de sistemas tutores inteligentes (STI) é uma opção popular [VanLehn 2006, Zawacki-Richter et al. 2019], corroborada por estudos que comprovam que sua eficácia é semelhante à da tutoria individual fornecida por tutores humanos [Jaques et al. 2012, D’mello and Graesser 2013]. O Personal Affective Tutor to Math (PAT2Math) é um desses STI, ajudando os alunos a resolver equações algébricas de 1º e 2º graus com uma variável [Kautzmann 2014].

A escolha do domínio do PAT2Math, equações lineares e quadráticas, foi feita devido ao assunto ser conhecido por eliciar emoções negativas nos alunos, como a frustração [Jaques et al. 2013]. Mas a frustração não é a única emoção esperada, pois o aprendizado é uma experiência carregada de afetividade [Kobayashi and Hara 1992]. Portanto, espera-se que os alunos experimentem uma gama de emoções positivas e negativas durante atividades de aprendizagem. De particular interesse para este artigo, é a emoção acadêmica da confusão, que tem o potencial de beneficiar ou prejudicar o aprendizado [Pekrun 2006]. Durante as atividades de aprendizagem, a confusão aumenta o foco dos alunos e fomenta a busca de conhecimento [D’mello and Graesser 2013], mas quando um aluno permanece confuso por longos períodos, a confusão pode se tornar tédio ou frustração, que são puramente prejudiciais ao aprendizado [Graesser and D’Mello 2011]. Além disso, a permanência dos alunos na emoção acadêmica da confusão deve ser regulada de acordo com a personalidade e o conhecimento prévio [D’Mello et al. 2007, Reis et al. 2018]. Para realizar essa tarefa, torna-se imperativo entender como o traço de personalidade dominante de um aluno e seus conhecimentos prévios impactam seu respectivo tempo de permanência no estado de confusão.

O objetivo deste trabalho é a modelagem estatística do tempo de permanência dos alunos no estado de confusão, de forma a verificar se o tempo de permanência em confusão, antes de transitar para outros estados, é influenciado por suas características de conhecimento prévio e personalidade.

## 2. Trabalhos Relacionados

Esta seção tem por objetivo descrever o estado da arte em trabalhos que levem em consideração um ou mais dos seguintes aspectos, em ambientes computacionais de aprendizagem: traços de personalidade dos alunos, conhecimento prévio, dinâmica de afeto e tempo de permanência em emoções específicas. Para isso, foi realizado uma busca nas bases da ACM, IEEE, Springer, Scopus e Science Direct, utilizando variações das seguin-

tes palavras chave, em português e inglês: *sistemas tutores inteligentes, tempo de permanência, emoções acadêmicas, dinâmica de afeto personalidade, conhecimento prévio*. Da amostra inicial de 640 artigos, 70 foram posteriormente descartados por duplicação e outros oito por estarem escritos em idiomas que não o inglês ou português. Por fim, foi realizada a leitura do título, resumo e palavras-chave dos 562 artigos restantes, culminando na seleção dos cinco trabalhos relacionados discutidos neste capítulo.

O trabalho de [D’Mello et al. 2012] (**Artigo #1**<sup>1</sup>) é considerado pioneiro no uso empírico de um STI para monitorar e registrar as transições entre estados afetivos durante tarefas complexas de aprendizagem. O experimento realizado fez uso do STI AutoTutor. Alunos de graduação ( $n=28$ ) tiveram seus rostos e telas gravados durante uma sessão de 32 minutos no AutoTutor, onde eles respondiam questões desafiadoras sobre hardware, internet e sistemas operacionais. Posteriormente, as gravações foram revistas pelos tutorados e anotadores de afeto treinados, de forma a rotular as emoções identificadas em intervalos de 20 segundos. Na etapa de análise, os autores aplicaram técnicas de inferência Bayesiana para modelar as transições mais prováveis entre as emoções acadêmicas, obtendo resultados que permitiram a confirmação do que os autores haviam postulado, referente às transições mais prováveis a partir da confusão: frustração e engajamento.

[D’Mello and Graesser 2012] (**Artigo #2**) investigaram as transições entre diferentes emoções durante atividades complexas de aprendizagem, culminando em sua proposta do modelo da dinâmica dos afetos. Para coletar insights sobre as prováveis transições de estado dos alunos, os autores conduziram dois estudos em que os participantes tiveram que completar uma sessão de 32 a 35 minutos no AutoTutor STI e auto-relato em 100 pontos diferentes durante a sessão de tutoria. Os resultados deste estudo abriram caminho para que os pesquisadores compreendam melhor o fluxo de afeto que os alunos sofrem durante a aprendizagem, bem como a importância da utilização correta da criação de impasses e desequilíbrios cognitivos em STIs.

[Eagle and Barnes 2014] (**Artigo #3**) se propuseram a investigar se um STI que fornece feedback automático aumenta o tempo de uso do sistema pelos alunos. Os autores utilizaram duas versões do tutor de lógica proposicional Deep Thought STI. A versão experimental (EV) do STI gera e fornece dicas e feedback automáticos para os alunos à medida que avançam, enquanto a versão regular (RV) fornece feedback ao final de cada atividade. A experimentação dividiu 105 alunos utilizando o EX, e os 98 utilizando o RV. Os autores utilizaram técnicas de análise de sobrevivência para modelar o tempo de permanência dos alunos no STI. As covariáveis levadas em consideração foram o desempenho dos alunos no STI, sua duração para terminar cada problema e se o aluno estava usando o VE ou RV. Ao analisar os resultados, evidenciou-se que houve diferença substancial entre as curvas de sobrevivência entre grupos, sendo que o grupo EV permaneceu no STI por três minutos a mais.

O estudo de [Di Leo et al. 2019] (**Artigo #4**) explorou o papel das transições de estado entre emoções acadêmicas durante o aprendizado complexo. Os autores realizaram três experimentos distintos em que alunos de 5ª e 6ª séries do ensino fundamental resolviam questões de matemática. Durante o experimento, os alunos foram instruídos à reportar em voz alta as emoções sentidas em determinados momentos, para que suas

---

<sup>1</sup>Número utilizado como identificador do artigo na Tabela 1

emoções pudessem ser posteriormente analisadas. Após análise, os autores concluíram que os alunos frustrados tendem a fazer a transição para outras emoções negativas (ou seja, tédio, ansiedade, frustração) com frequência. Também foi demonstrado que, uma vez no estado de confusão, os aprendizes gravitam mais comumente para emoções negativas, corroborando com o modelo de dinâmica de afetos [D’Mello and Graesser 2012].

Por fim, [Reis et al. 2018] (**Artigo #5**) se concentrou em analisar a interação entre conhecimento prévio em álgebra e traços dominantes de personalidade no tempo de permanência do aluno no estado de confusão, antes que ele transite para frustração. A experimentação foi realizada com 30 participantes e teve duração de 90 minutos. Os alunos tiveram seus rostos gravados durante a resolução de um conjunto de problemas de álgebra em uma ferramenta computacional. Os vídeos gravados foram revisados por dois codificadores, que também anotaram manualmente os horários de início e término em que cada aluno expressou as emoções consideradas. Para analisar o tempo aproximado de permanência dos alunos no estado de confusão, os autores usaram a análise de sobrevivência. Os resultados obtidos sugerem que tanto o conhecimento prévio em álgebra quanto os traços de personalidade influenciam o tempo de permanência do aluno na confusão, antes que este transite para frustração ou tédio. Além disto, foi possível identificar que alunos com traços dominantes de personalidade neurótica e pontuações baixas no conhecimento prévio permanecem por menos tempo no estado de confusão, dessa forma, transicionando mais rapidamente para emoções negativas.

**Tabela 1. Distinções entre o trabalho proposto e seus relacionados.**

#	Experimentação:		Investigou:	Considerou:	
	Contexto	Participantes	Tempo de Permanência	Personal.	Conhec. prev.
1	Universidade	28	Não	Não	Não
2	Universidade	28	Não	Não	Não
3	Universidade	25	Não	<b>Sim</b>	Não
4	Universidade	203	<b>Sim</b>	Não	<b>Sim</b>
5	<b>Fundamental</b>	32	<b>Sim</b>	Não	Não
*	<b>Fundamental</b>	25	<b>Sim</b>	<b>Sim</b>	<b>Sim</b>

As principais distinções entre este trabalho e os trabalhos relacionados são mostrados na Tabela 1 (Trabalho Proposto identificado como \* na coluna #). Ampliando o trabalho de [Reis et al. 2018], utilizando dados coletados de [Morais 2018], este trabalho tem como objetivo analisar e responder se os traços de personalidade dominantes e o conhecimento prévio dos estudantes impactam na sua tolerância em permanecer no estado de confusão. As três principais distinções deste estudo são: (i) Foi considerado o traço de personalidade dominante de amabilidade, aumentando para três o número de traços examinados; (ii) O conhecimento prévio de cada estudante foi derivado a partir de suas interações anteriores no próprio STI, onde a técnica *Bayesian Knowledge Tracing* (BKT) foi utilizada para inferir seu domínio dos componentes de conhecimento; (iii) Técnicas de análise de sobrevivência semi-paramétricas foram utilizadas, de forma a modelar as covariáveis (personalidade e conhecimento prévio), evitando a necessidade de realizar inferências sobre a distribuição dos dados.

### 3. Trabalho Desenvolvido

O objetivo deste trabalho é criação de um modelo estatístico do tempo de permanência dos alunos na emoção acadêmica de confusão, levando-se em consideração seus diferentes traços de personalidade e conhecimento prévio em álgebra. O interesse no tempo de permanência de alunos em confusão se deve à sua correlação positiva com a aprendizagem, bem como ao seu potencial prejudicial nos casos em que os alunos permanecem confusos por longos períodos de tempo [Craig et al. 2004, D’Mello et al. 2007]. O modelo de aluno a ser criado visa auxiliar o STI a reagir aos alunos que estejam atingindo seu limite de tolerância de permanência em confusão, mitigando possíveis transições para emoções acadêmicas puramente negativas.

Para a criação do modelo foram aplicadas as seguintes técnicas de análise de sobrevivência:

- O método Multivariado de Riscos Proporcionais de Cox foi utilizado para avaliar o impacto da personalidade e do conhecimento prévio do aluno sobre seu tempo de permanência na confusão.
- O método de Teste Logrank e Riscos Proporcionais de Cox foi usado para a comparação das curvas de sobrevivência de diferentes grupos de alunos.
- O método de Kaplan-Meier foi empregado para a plotagem das curvas de sobrevivência e dos tempos limiar e mediano de tolerância de permanência em confusão, antes da transição para afetos positivos ou afetos negativos.

O STI educacional utilizado neste trabalho é o PAT2Math. O PAT2Math é um STI *web* baseado em passos que provê assistência aos alunos enquanto resolvem equações algébricas de 1° e 2° grau [Kautzmann 2014], fornecendo dicas e *feedback* personalizado aos alunos à cada passo durante a resolução das equações. Os dados analisados neste trabalho foram coletados por [Morais 2018] em 10 sessões, com média de 40 minutos de duração, de 55 alunos utilizando o PAT2Math, os quais tiveram seus rostos e telas gravados, para posterior análise e atribuição de rótulos de emoção. Os alunos eram provenientes de duas turmas do sétimo ano de uma escola privada do sul do Brasil, com idades entre 12 e 13 anos.

#### 3.1. Dados de Personalidade

A correlação entre traços de personalidade e a aprendizagem vêm sendo estudada desde o século XIX [Raad and Schouwenburg 1996]. Em 1991, [Miller 1991] recomendou que, para maximizar a aprendizagem, os tutores devem considerar os traços de personalidade de seus alunos, bem como os diferentes estilos de aprendizagem que podem ser mais eficazes para cada um. De acordo com o modelo dos Cinco Grandes Fatores de Personalidade [Goldberg 1981, McCrae and Costa 1983], os cinco traços dominantes de personalidade são: abertura, amabilidade, conscienciosidade, extroversão e neuroticismo. Os três traços de personalidade considerados neste trabalho são o neuroticismo, a extroversão e a amabilidade, devido ao alto impacto evidenciado destes traços no desempenho acadêmico dos alunos [D’mello and Graesser 2013, Reis et al. 2017, Reis 2019], além do fato de apenas cinco alunos participantes das sessões possuírem os traços de personalidade dominantes não considerados (abertura e conscienciosidade).

Após a última sessão, os alunos responderam um questionário de personalidade. Esse questionário identifica os traços de personalidade dos alunos com base na teoria dos cinco grandes fatores, tendo sido escrito em português e validado para o uso no Brasil por [Barbosa 2009] em sua tese de doutoramento. O questionário possui 20 questões, com respostas seguindo uma escala Likert variando de 1 a 5, onde o valor 1 denota completa discordância e o valor 5 plena concordância com a afirmativa. As questões buscam obter relatos, por exemplo, do quanto o participante se considera detalhista, ou com qual facilidade fica ansioso ou tímido. Contando com quatro questões para cada um dos cinco traços de personalidade, o traço dominante era atribuído através da soma dos valores atribuídos pelo participante. Logo, alunos com pontuação próxima de 20 para questões pertinentes à um traço específico de personalidade eram atribuídos à este, enquanto pontuações com valores próximos à 4 denotavam baixa presença deste no participante.

### 3.2. Coleta dos Rótulos de Emoções

Para a atribuição dos rótulos de emoções aos vídeos dos alunos, [Morais 2018] propuseram, desenvolveram e validaram o protocolo EmAP-ML. O protocolo possui etapas específicas para o treinamento e teste dos codificadores humanos, para torná-los aptos para anotar emoções apenas quando atingirem um coeficiente Kappa de Cohen igual, ou superior, à 0,6. Neste protocolo, os codificadores podem anotar as emoções e comportamentos de um único aluno por vez, capturando as transições de emoções em janelas (clipes) de cinco segundos, sendo ainda possível a anotação de mais de uma emoção por clipe. Três codificadores foram treinados e, subseqüentemente, fizeram a análise e anotação das emoções de 25 alunos distintos empregados neste trabalho.

### 3.3. Dados de Conhecimento do Aluno

Para inferir o conhecimento prévio de álgebra de cada aluno, foi desenvolvido um modelo BKT, utilizando dados do aluno e do módulo de domínio do STI PAT2Math. Para cada aluno considerado na experimentação deste trabalho, foram extraídas do módulo do aluno informações pertinentes às equações resolvidas por cada aluno, número de passos corretos/incorretos, quantidade de respostas corretas/incorretas, número de dicas solicitadas e os componentes de conhecimento praticados pelo aluno. Quanto aos componentes de conhecimento abrangidos pelo STI, alguns exemplos são: adição, subtração, mínimo múltiplo comum, operação inversa e propriedade distributiva. Para cada equação considerada pelo PAT2Math STI, foi feita uma inferência quanto ao número de passos (operações algébricas) necessários para sua resolução. Subseqüentemente, para posterior uso na técnica de BKT, foram calculados quantos passos e equações cada aluno acertou, o número de acertos obtidos nos últimos cinco segundos<sup>2</sup> e qual o total de operações corretamente respondidas pelo aluno, considerando cada um dos componentes de conhecimento trabalhados. Todos os elementos acima também foram calculados considerando apenas passos, equações e operações respondidas incorretamente por cada aluno. Na fase de geração dos rótulos do protocolo, um total de 2099 rótulos de emoções, sendo a presença ou ausência de cada uma das quatro emoções consideradas: confusão, engajamento, frustração e tédio.

A aplicação da técnica BKT sob os dados de conhecimento dos alunos resultou em uma matriz  $25 \times 10$  contendo, para cada um dos 25 alunos considerados, a sua respectiva

<sup>2</sup>O protocolo de anotação de emoções, EmAP-ML, utiliza janelas de 5 segundos.

probabilidade de ter obtido domínio de cada um dos 10 componentes de conhecimento, com probabilidades variando entre 0.5922 to 0.8126. Por fim, foi aplicado o método de *Median-Split* na matriz resultante, dada a preferência de alguns métodos de análise de sobrevivência em trabalhar com valores discretos [Iacobucci et al. 2015]. A aplicação do método *Median-Split* resultou nos grupos k0 e k1, onde k0 contém 13 alunos cujas probabilidades de conhecimento prévio estavam no intervalo  $[0, 5922, 0, 7477]$ , e k1 contendo os 12 alunos restantes, cujas probabilidades de conhecimento prévio estão no intervalo  $[0, 7487, 0, 8126]$ .

### 3.4. Análise de Sobrevivência e Modelagem

A modelagem estatística por meio da análise de sobrevivência é uma ferramenta poderosa quando há interesse em analisar o tempo de sobrevivência  $T$ , também conhecido como tempo de permanência, dos indivíduos de uma amostra, considerando um período de tempo  $t$ . Além disso, técnicas multivariadas, como os Riscos Proporcionais de Cox, permitem entender como as diferentes covariáveis,  $x_1 \dots x_p$ , impactam o tempo de sobrevivência [Saccaro et al. 2019], evidenciando as conexões, semelhanças, e diferenças que essas variáveis têm no modelo [Trivelloni and Hochheim 1998]. Em linhas gerais, o evento  $\delta_i$  que interessa a este estudo é o tempo de permanência do aluno  $t$  em confusão, antes de transitar para outras emoções acadêmicas. O período  $t$  é igual a cinco minutos, que é a quantidade de tempo que a sessão de cada aluno foi anotada. As covariáveis de interesse são os traços de personalidade de cada aluno e o conhecimento prévio de álgebra.

Os coeficientes estatísticos fornecidos na Tabela 2 permitem a compreensão do impacto de cada covariável no modelo. O teste de Logrank do modelo mostra que há diferença significativa entre as curvas de sobrevivência para grupos distintos no modelo, com valor de  $p < 0,00001$ . Para determinar o impacto dos coeficientes nas curvas de sobrevivência, é escolhido um valor de referência de cada covariável. Neste trabalho, os valores de referência escolhidos são aqueles com a menor variância em sua função de sobrevivência ( $S(t)$ ). O **coeficiente de regressão** determina o risco de ocorrência de um evento para cada covariável em relação ao valor de referência, portanto, valores positivos representam maior chance de evento e valores negativos, maior chance de sobrevivência. Por exemplo, tanto as personalidades extrovertidas quanto as agradáveis têm uma probabilidade maior de se afastar da confusão mais rapidamente do que os alunos neuróticos, enquanto os alunos do grupo com maior conhecimento prévio de álgebra (k1) permanecem confusos por mais tempo do que os alunos do grupo com menor conhecimento prévio (k0). Por fim, o **Teste-Z** e o **p-value** são usados para avaliar se o coeficiente  $\beta$  de uma determinada covariável é significativamente diferente de 0 e, portanto, contribui para o *fit* geral do modelo [Kassambara 2016].

**Tabela 2. Coeficientes do modelo de permanência em confusão dos alunos.**

	Neuroticismo*	Extroversão	Amabilidade	k0*	k1
<b>Coef. Regr.</b>	1	0,6952	0,3441	1	-0,2236
<b>Teste-Z</b>	-	5.531	0.347	-	-2.510
<b>p-value</b>	-	¡ 0,00001	0,0005	-	0,0120

Teste Logrank  $p - value < 0.00001$ . (\*) Valor de referência.

A representação gráfica do modelo de permanência dos alunos no estado de confusão, obtido através da aplicação do método de Riscos Proporcionais de Cox e plotado com o auxílio da técnica de Kaplan-Meier, pode ser observado na Figura 1. O tempo médio de permanência em confusão de cada grupo é representado no gráfico pelas linhas tracejadas, sendo de 42 segundos para os alunos com traço dominante de neuroticismo, 17 segundos para alunos com traço de amabilidade e apenas 10 segundos para os extrovertidos.

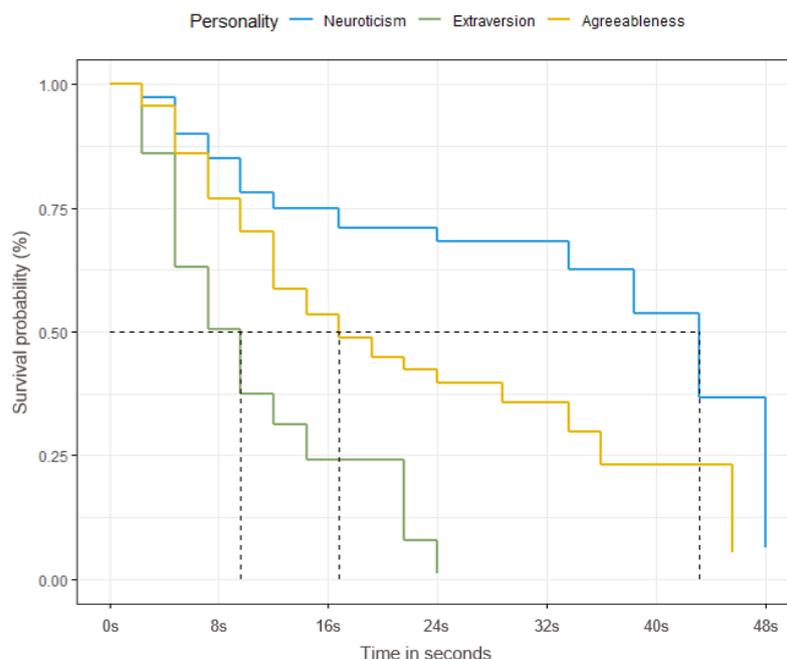
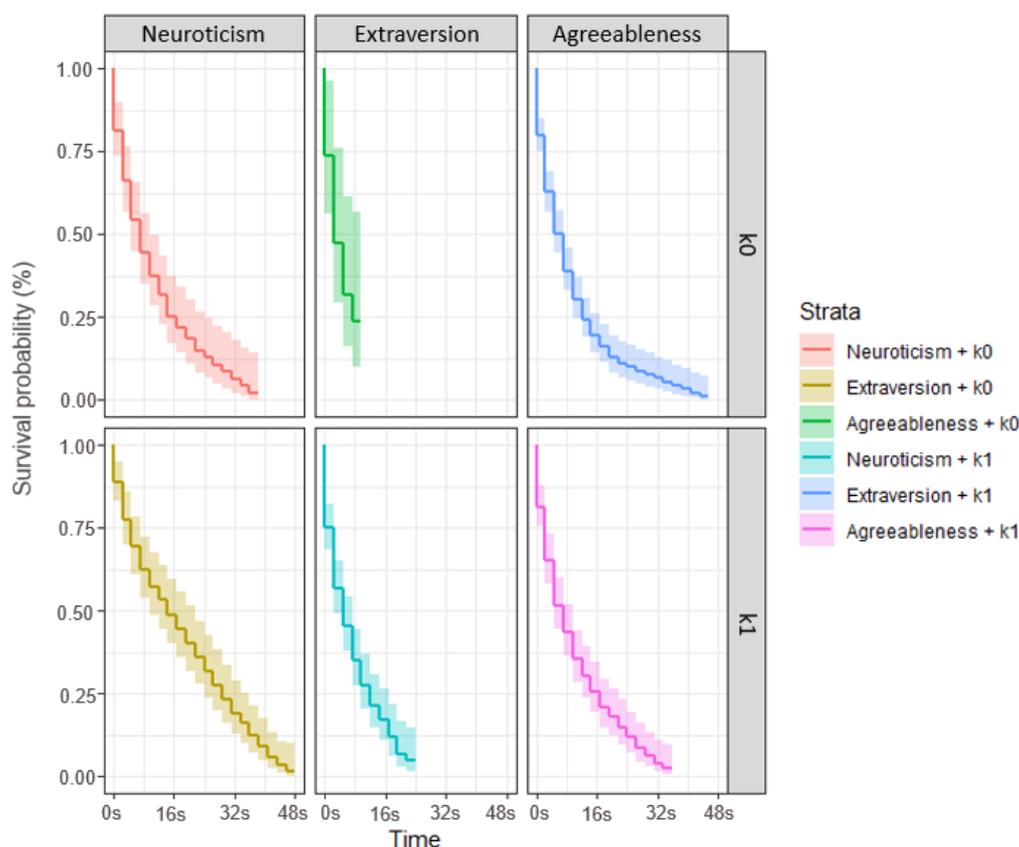


Figura 1. Representação do modelo de tempo de permanência em confusão.

#### 4. Resultados e Discussões

Como visualmente observado no gráfico do modelo apresentado na Figura 1 e na Tabela 2 de coeficientes estatísticos, existem significativas diferenças entre as curvas de sobrevivência de cada grupo, considerando tanto a personalidade quanto o seu conhecimento prévio dos alunos. Um gráfico composto é mostrado na Figura 2, descrevendo o tempo de permanência na confusão antes da transição para outras emoções acadêmicas, para os alunos em cada uma das seis combinações possíveis de traços de personalidade dominantes e grupo de conhecimento.

Estudantes **neuróticos** têm o maior tempo de permanência em confusão, antes de transitarem para outras emoções acadêmicas, com um tempo limite de 40 segundos para os alunos do grupo com menos conhecimento prévio de álgebra (**k0**) e 48 segundos para os alunos do grupo com níveis mais altos de conhecimento prévio (**k1**). Esses resultados diferem dos obtidos no trabalho de [Reis et al. 2018], em que alunos neuróticos conseguiram lidar com a confusão por um período menor de tempo quando comparados a alunos extrovertidos do mesmo grupo de conhecimento. Uma possível explicação para essa observação é a ligação entre neuroticismo e ansiedade, prejudicial ao aprendizado em altas doses, mas quando experimentado de forma leve,



**Figura 2. Taxa de risco do modelo de tempo de permanência do aluno em confusão.**

demonstrou ter um efeito estimulante nos níveis de engajamento da tarefa de alunos neuróticos [Poropat 2011, Ciorbea and Pasarica 2013]. Além disso, há apenas uma pequena diferença nas pontuações de conhecimento do grupo **k0** e do grupo **k1**, o que também pode contribuir para a pequena diferença no tempo de permanência observada nos dois grupos.

Os alunos com personalidade **extrovertida** são os que têm menor permanência em confusão, com um tempo limite de permanência de 6 segundos para alunos em **k0** e 24 segundos para alunos em **k1**. Dada a propensão desta personalidade a afetos positivos, como engajamento [Shanahan et al. 2014b], e os vários estudos ligando extroversão com confiança e raciocínio rápido em ambientes acadêmicos [Nussbaum 2002, Nussbaum and Bendixen 2003, Poropat 2009], é concebível que esses alunos estivessem simplesmente respondendo rapidamente às perguntas. Outra inferência viável sobre esse resultado é o fato de que alunos extrovertidos são altamente engajados e interativos quando se deparam com métodos não convencionais de aprendizagem [Schmeck and Lockhart 1983, Murphy et al. 2020], como no caso do STI PAT2Math.

A **amabilidade** possui, notavelmente, o menor impacto no tempo de permanência, independentemente do conhecimento prévio do aluno. O tempo médio de permanência em confusão é de 8 segundos para ambos os grupos, e seu tempo limite é de 45 segundos para os alunos do grupo **k0** e 36 para alunos no grupo **k1**. O baixo impacto do conhecimento prévio nos alunos com o traço de amabilidade é consubstanci-

ada pela correlação entre esta personalidade e altos níveis de adaptabilidade ao ambiente [Thoresen et al. 2004], bem como a constância no desempenho acadêmico destes indivíduos [Shanahan et al. 2014a, Vedel and Poropat 2017].

## 5. Conclusões

Emoções são intrínsecas à aprendizagem [Pekrun et al. 2002]. A miríade de emoções experimentadas pelos alunos em ambientes educacionais são conhecidas como emoções acadêmicas. Enquanto emoções acadêmicas positivas (por exemplo, engajamento) são positivamente correlacionadas à aprendizagem, emoções negativas (por exemplo, frustração ou tédio) têm o efeito oposto, dificultando a motivação e a vontade de aprender, potencialmente levando a efeitos duradouros, como a síndrome do impostor. A emoção acadêmica da confusão, no entanto, reside no meio de campo, podendo melhorar ou dificultar o aprendizado. Quando experimentada moderadamente, a confusão incita os alunos a buscar conhecimento, aumentando seu foco. Mas, a confusão experimentada por longos períodos pode se tornar frustração ou tédio.

Os tutores humanos são treinados para lidar eficientemente com alunos com personalidades e estilos de aprendizagem distintos, bem como para detectar pistas emocionais e identificar lacunas no conhecimento do tutorado [VanLehn 2006]. Torna-se imperativo então que, para que os STIs atinjam um nível de eficiência igual ou superior ao dos tutores humanos, considerem aspectos de personalidade e possíveis lacunas no conhecimento do aluno (conhecimento prévio), auxiliando na regulação das emoções do estudante. Embora já existam estudos que tentam modelar o tempo de permanência do aluno em emoções acadêmicas específicas, eles apresentam uma ou mais das seguintes lacunas, abordadas neste trabalho: (i) realizou-se experimentação apenas em adultos; (ii) traços de personalidade não foram considerados, ou considerou-se no máximo dois traços; (iii) não se considerou o conhecimento prévio do aluno; (iv) não se recorreu a um protocolo validado para rotular emoções dos alunos.

Abordando as lacunas mencionadas acima, este trabalho se propôs a analisar e responder se os traços de personalidade dominantes e o conhecimento prévio de álgebra de (i) 25 estudantes do ensino fundamental, com idades entre 12 e 13 anos, têm ou não impacto no seu tempo de permanência em confusão. Entre suas principais distinções dos trabalhos relacionados, este estudo (ii) considerou três traços de personalidade dominantes, os quais possuem correlação (positiva ou negativa) com o aprendizado [De Feyter et al. 2012, Rammstedt et al. 2017, Nießen et al. 2020]. Inferiu o (iii) conhecimento prévio de álgebra do aluno por meio do método BKT, que considera o nível de domínio do aluno sobre cada componente do conhecimento empregado. E, por fim, obteve os rótulos das emoções acadêmicas vivenciadas pelos alunos por meio da aplicação do (iv) protocolo EmAP-ML, executado por três codificadores treinados.

Os resultados obtidos apresentaram fortes evidências de que ambas as covariáveis, personalidade e conhecimento prévio de álgebra, exercem influência sobre o tempo de permanência do aluno na confusão. Mas, a covariável de personalidade aparenta influenciar mais solidamente o tempo de permanência dos alunos em confusão, antes de fazer transitarem para outras emoções acadêmicas. Além disto, foi observado que alunos extrovertidos permanecem por menor tempo na emoção acadêmica de confusão, independentemente do seu nível de conhecimento prévio de álgebra. Corroborando com a lite-

ratura, que afirma que alunos com o traço de personalidade de amabilidade apresentam constância em ambientes acadêmicos [Shanahan et al. 2014a, Vedel and Poropat 2017], seu tempo de permanência em confusão foi semelhante, independente do conhecimento prévio. Por fim, em desacordo com os resultados obtidos por [Reis et al. 2018], os alunos neuróticos foram percebidos como tolerantes à confusão por um período maior de tempo. Presume-se que este resultado esteja ligado a dois aspectos, (1) altos índices de conhecimento prévio observado nos alunos neuróticos e (2) baixos níveis de ansiedade eliciados durante as atividades no STI PAT2Math.

## Referências

- Amato, L. (2018). *Math anxiety: The impact on traditionally underserved and marginalized adult female undergraduate students in elementary statistics*. PhD thesis, Northeastern University of Boston.
- Barbosa, A. (2009). *Modelo hierárquico de fobias infanto-juvenis: Testagem e relação com os estilos maternos*. PhD thesis, Universidade Federal do Rio Grande do Norte.
- Bloom, B. (1984). The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. *Educational Researcher*, 13(6):4–16.
- Brooks, A. W. (2014). Get excited: reappraising pre-performance anxiety as excitement. *Journal of Experimental Psychology: General*, 143(3):1144.
- Ciorbea, I. and Pasarica, F. (2013). The study of the relationship between personality and academic performance. *Procedia-Social and Behavioral Sciences*, 78:400–404.
- Craig, S., Graesser, A., Sullins, J., and Gholson, B. (2004). Affect and learning: an exploratory look into the role of affect in learning with autotutor. *Journal of educational media*, 29(3):241–250.
- De Feyter, T., Caers, R., Vigna, C., and Berings, D. (2012). Unraveling the impact of the big five personality traits on academic performance: The moderating and mediating effects of self-efficacy and academic motivation. *Learning and individual Differences*, 22(4):439–448.
- Di Leo, I., Muis, K. R., Singh, C. A., and Psaradellis, C. (2019). Curiosity... confusion? frustration! the role and sequencing of emotions during mathematics problem solving. *Contemporary educational psychology*, 58:121–137.
- D’mello, S. and Graesser, A. (2013). Autotutor and affective autotutor: Learning by talking with cognitively and emotionally intelligent computers that talk back. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, 2(4):1–39.
- D’Mello, S., Picard, R. W., and Graesser, A. (2007). Toward an affect-sensitive autotutor. *IEEE Intelligent Systems*, 22(4):53–61.
- D’Mello, S., Taylor, R., and Graesser, A. (2012). Monitoring affective trajectories during complex learning. *Encyclopedia of the Sciences of Learning*, pages 203–208.
- D’Mello, S. and Graesser, A. (2012). Dynamics of affective states during complex learning. *Learning and Instruction*, 22(2):145–157.
- Eagle, M. and Barnes, T. (2014). Survival analysis on duration data in intelligent tutors. In *International Conference on Intelligent Tutoring Systems*, pages 178–187. Springer.

- Goldberg, L. R. (1981). Language and individual differences: The search for universals in personality lexicons. *Review of personality and social psychology*, 2(1):141–165.
- Graesser, A. and D’Mello, S. (2011). *Theoretical Perspectives on Affect and Deep Learning*. Springer New York, first edition.
- Iacobucci, D., Posavac, S. S., Kardes, F. R., Schneider, M. J., and Popovich, D. L. (2015). Toward a more nuanced understanding of the statistical properties of a median split. *Journal of Consumer Psychology*, 25(4):652–665.
- Jaques, P. A., Nunes, M. A. S., Isotani, S., and Bittencourt, I. (2012). Computação afetiva aplicada a educação: Dotando sistemas tutores inteligentes de habilidades sociais. In *Anais do Workshop de Desafios da Computação Aplicada à Educação*, pages 50–59.
- Jaques, P. A., Seffrin, H., Rubi, G., de Moraes, F., Ghilardi, C., Bittencourt, I. I., and Isotani, S. (2013). Rule-based expert systems to support step-by-step guidance in algebraic problem solving: The case of the tutor pat2math. *Expert Systems with Applications*, 40(14):5456–5465.
- Kassambara, A. (2016). Cox proportional hazards model in r. Available at: <<http://www.sthda.com/english/wiki/cox-proportional-hazards-model>>. Accessed on: December 28, 2021.
- Kautzmann, T. R. (2014). Um modelo de agente metacognitivo para o treinamento da habilidade de monitoramento do conhecimento: um estudo de caso com o sistema tutor inteligente pat2math. Master’s thesis, Universidade do Vale do Rio dos Sinos.
- Kobayashi, H. and Hara, F. (1992). Recognition of six basic facial expression and their strength by neural network. In [1992] *Proceedings IEEE International Workshop on Robot and Human Communication*, pages 381–386. IEEE.
- McCrae, R. R. and Costa, P. T. (1983). Social desirability scales: More substance than style. *Journal of consulting and clinical psychology*, 51(6):882–888.
- Miller, A. (1991). Personality types, learning styles and educational goals. *Educational psychology*, 11(3-4):217–238.
- Moraes, F. d. (2018). Detecção e predição de estados afetivos baseados em mineração de dados educacionais: Considerando a personalidade do aluno para aumentar a precisão da detecção. Master’s thesis, Universidade do Vale do Rio dos Sinos.
- Murphy, L., Eduljee, N. B., Croteau, K., and Parkman, S. (2020). Relationship between personality type and preferred teaching methods for undergraduate college students. *International Journal of Research in Education and Science*, 6(1):100–109.
- Nießen, D., Danner, D., Spengler, M., and Lechner, C. M. (2020). Big five personality traits predict successful transitions from school to vocational education and training: a large-scale study. *Frontiers in psychology*, pages 1–18.
- Nussbaum, E. M. (2002). How introverts versus extroverts approach small-group argumentative discussions. *The Elementary School Journal*, 102(3):183–197.
- Nussbaum, E. M. and Bendixen, L. D. (2003). Approaching and avoiding arguments: The role of epistemological beliefs, need for cognition, and extraverted personality traits. *Contemporary Educational Psychology*, 28(4):573–595.

- Pekrun, R. (2006). The control-value theory of achievement emotions: Assumptions, corollaries, and implications for educational research and practice. *Educational psychology review*, 18(4):315–341.
- Pekrun, R., Goetz, T., Titz, W., and Perry, R. P. (2002). Academic emotions in students' self-regulated learning and achievement: A program of qualitative and quantitative research. *Educational psychologist*, 37(2):91–105.
- Poropat, A. E. (2009). A meta-analysis of the five-factor model of personality and academic performance. *Psychological bulletin*, 135(2).
- Poropat, A. E. (2011). The eysenckian personality factors and their correlations with academic performance. *British Journal of Educational Psychology*, 81(1):41–58.
- Raad, B. and Schouwenburg, H. (1996). Personality in learning and education: a review. *European Journal of Personality*, 10:303–336.
- Rammstedt, B., Danner, D., and Lechner, C. (2017). Personality, competencies, and life outcomes: results from the german piae longitudinal study. *Large-scale assessments in education*, 5(1):1–19.
- Reis, H., Alvares, D., Jaques, P., and Isotani, S. (2018). Analysis of permanence time in emotional states: A case study using educational software. In *International conference on intelligent tutoring systems*, pages 180–190. Springer.
- Reis, H. M. (2019). *Regulação emocional personalizada para sistemas tutores inteligentes por meio de traços de personalidade*. PhD thesis, Universidade de São Paulo.
- Reis, H. M., Jaques, P. A., and Isotani, S. (2017). Sistemas tutores inteligentes que reconhecem o estado emocional do estudante: Um mapeamento sistemático. *Research and Innovation in Brazilian Education*, pages 101–114.
- Saccaro, A., França, M. T. A., and Jacinto, P. d. A. (2019). Fatores associados à evasão no ensino superior brasileiro: um estudo de análise de sobrevivência para os cursos das áreas de ciência, matemática e computação e de engenharia, produção e construção em instituições públicas e privadas. *Estudos Econômicos (São Paulo)*, 49:337–373.
- Schmeck, R. R. and Lockhart, D. (1983). Introverts and extraverts require different learning environments. *Educational leadership*, 40(5):54–55.
- Seffrin, H., Rubi, G., Ghilardi, C., Morais, F., Jaques, P., Isotani, S., and Bittencourt, I. I. (2012). Dicas inteligentes no sistema tutor inteligente pat2math. In *Brazilian symposium on computers in education (simpósio brasileiro de informática na educação-sbie)*, volume 23.
- Shanahan, M. J., Bauldry, S., Roberts, B. W., Macmillan, R., and Russo, R. (2014a). Personality and the reproduction of social class. *Social Forces*, 93(1):209–240.
- Shanahan, M. J., Hill, P. L., Roberts, B. W., Eccles, J., and Friedman, H. S. (2014b). Conscientiousness, health, and aging: the life course of personality model. *Developmental Psychology*, 50(5):1407.
- Thoresen, C. J., Bradley, J. C., Bliese, P. D., and Thoresen, J. D. (2004). The big five personality traits and individual job performance growth trajectories in maintenance and transitional job stages. *Journal of applied psychology*, 89(5):835.

- Trivelloni, C. A. and Hochheim, N. (1998). Avaliação de imóveis com técnicas de análise multivariada. In *CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFUN-  
CIONALITÁRIO*, volume 3.
- VanLehn, K. (2006). The behavior of tutoring systems. *International journal of artificial intelligence in education*, 16(3):227–265.
- Vedel, A. and Poropat, A. E. (2017). Personality and academic performance. *Encyclopedia of personality and individual differences*, pages 1–9.
- Zaslavsky, C. (1994). *Fear of math: How to get over it and get on with your life*. Rutgers University Press.
- Zawacki-Richter, O., Marín, V. I., Bond, M., and Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education—where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1):1–27.
- Zeidner, M. (1998). *Test anxiety: The state of the art*. Springer Science & Business Media, first edition.