

# Tamanho Ótimo de Amostra para Análise do Desempenho de Estudantes em Ambientes Educacionais Ubíquos

Taffarel Brant-Ribeiro<sup>1</sup> e Renan Gonçalves Cattelan<sup>2</sup>

<sup>1</sup>Instituto Federal do Sul de Minas Gerais (IFSULDEMINAS)  
Passos – Minas Gerais – Brasil

<sup>2</sup>Faculdade de Computação – Universidade Federal de Uberlândia (UFU)  
Uberlândia – Minas Gerais – Brasil

brant.ribeiro@ifsulde Minas .edu.br, renan@ufu.br

**Abstract.** *Academic usage of Ubiquitous Computing allows the automation of educational activities through the creation of Ubiquitous Learning Environments. In the literature, researches that study such technologies tend to make comparisons among users, but do not verify initially if the studied samples size is able to represent the populations they are taken from. These analyzes result in inaccuracies due to lack of experimental precision in methods utilized during studies. This research explored this inconsistency and determined an optimum sample size of 25 students to analyze the performance of students which do not use educational technologies and of 20 students for classes that are in touch with educational systems. These results are relevant to researches that make use of human factors, since we show that samples with reduced amounts of data are able to comprise most part of the behavior of variables under analysis.*

**Resumo.** *O uso da Computação Ubíqua no escopo acadêmico permite automatizar atividades pedagógicas por meio da criação de Ambientes Educacionais Ubíquos. Na literatura, pesquisas que estudam tais tecnologias tendem a realizar comparações entre usuários, mas não averigam inicialmente se o tamanho das amostras estudadas é capaz de representar as populações das quais são retiradas. Tais análises resultam em informações inexatas, devido à falta de precisão experimental dos métodos utilizados nos estudos. Esta pesquisa explorou essa inconsistência e determinou um tamanho ótimo de amostra de 25 indivíduos para a análise do desempenho de alunos que não utilizam tecnologias educacionais no cotidiano e de 20 estudantes para turmas que possuem contato com sistemas educacionais durante os semestres letivos. Tais resultados se mostram relevantes para pesquisas que fazem uso de fatores humanos, pois demonstram que amostras com quantidades reduzidas de observações são capazes de compreender grande parte do comportamento das variáveis sob análise.*

## 1. Introdução

O constante uso de equipamentos tecnológicos possibilita que as pessoas mantenham-se conectadas à Internet durante a maior parte do tempo, realizando contínuas atividades de interação com dispositivos computacionais [Internet World Stats 2014]. Nas últimas décadas, os computadores propagaram-se de maneira intensa na sociedade, tornando-se

cada vez mais comuns e transformando-se em elementos onipresentes que entrelaçaram-se por completo ao modo de vida das pessoas. A esse paradigma atual de interatividade entre humanos e computadores atribui-se o nome de *Computação Ubíqua (UbiComp)*, cuja utilização possibilita que usuários sejam auxiliados por dispositivos computacionais de maneira transparente durante o exercício de suas tarefas do dia a dia [Weiser 1991].

No âmbito educacional, a *UbiComp* permite a automatização de atividades pedagógicas, contribuindo com processos de ensino/aprendizagem ao equipar salas de aula com dispositivos tecnológicos e criar *Ambientes Educacionais Ubíquos (AEUs)* [Zhao et al. 2010, Settle et al. 2011]. Nesse contexto, o emprego de *AEUs* permite realizar a integração de ambientes virtuais e reais de aprendizagem, eliminando limites físicos das salas de aula e abordando uma área de pesquisa intitulada *Aprendizagem Ubíqua (U-Learning)*, que preza pela capacidade de se criar, distribuir e obter conhecimento em qualquer local e circunstância [Aihua 2010, Kinshuk e Graf 2012].

Ao se trabalhar com sistemas educacionais, diversas questões despontam sobre a eficiência dessas tecnologias e quais benefícios elas propiciam ao âmbito acadêmico. Trabalhos neste escopo abrangem uma linha de pesquisa denominada *Learning Analytics (LA)*, compreendida como o processo de se coletar e analisar dados de discentes para estimar seus progressos acadêmicos e antever desempenhos futuros [Barneveld et al. 2012, Chatti et al. 2014]. Por meio de tais análises, torna-se possível conjecturar técnicas para otimizar processos de aprendizagem, aprimorando não apenas metodologias educacionais utilizadas, como também os ambientes em que tais atividades podem acontecer [Siemens e Long 2011, Ferreira e Andrade 2014].

Por ser uma temática de pesquisa contemporânea [Chatti et al. 2014], a área de *LA* ainda não dispõe completamente de um arcabouço bem fundamentado de métodos, heurísticas e padrões para a realização e replicação de pesquisas científicas. Na literatura, trabalhos sobre desempenho e adaptabilidade de usuários são frequentemente observados e abrem margem para diversas análises, como a verificação de ganhos para estudantes que fazem uso de ferramentas acadêmicas [Settle et al. 2011]. No entanto, a maioria dessas pesquisas preocupa-se apenas em fazer comparações entre usuários, expondo que existem aumentos de desempenho entre grupos observados [Aihua 2010, Wieling e Hofman 2010, Dickson et al. 2012], mas não dedicando-se em averiguar inicialmente se o tamanho das amostras analisadas é robusto o suficiente para representar com alto nível de confiabilidade as populações das quais são retiradas.

Diversos fatores influenciam a precisão e a confiabilidade experimentais, dentre eles o nível de heterogeneidade dos ambientes e do material experimental sob análise [Gomez e Gomez 1984, Steel et al. 1997]. Para se diminuir o erro experimental, é necessário utilizar amostras com dimensões adequadas e capazes de suprir as características das populações observadas. Dentre os métodos existentes para estimar o tamanho ótimo de amostras, o *Método de Máxima Curvatura Modificado (MMCM)*, apresentado por [Lessman e Atkins 1963] e [Meier e Lessman 1971], é bastante empregado por fornecer resultados precisos ao estabelecer uma equação de regressão para explicar a relação entre os coeficientes de variação e seus respectivos tamanhos de amostra [Silva et al. 2003].

Com essas assertivas em mente, esta pesquisa objetivou determinar o tamanho ótimo de amostra para a análise do desempenho de estudantes em contato com *AEUs*.

No decorrer desta investigação, enxergou-se também a necessidade de se determinar o tamanho ótimo para analisar alunos de graduação que não estão em contato com tais tecnologias, de modo a ser possível traçar um paralelo entre os resultados obtidos e se recomendar uma estimativa capaz de compreender ambas as circunstâncias. Para este fim, o restante deste artigo está estruturado da seguinte maneira: na Seção 2, o *AEU* utilizado nesta pesquisa é detalhado; na Seção 3, material e métodos são demonstrados; na Seção 4, resultados são apresentados e discutidos; na Seção 5, trabalhos relacionados são revisados e, por fim, considerações finais são pontuadas na Seção 6.

## 2. Classroom eXperience

O *Classroom eXperience (CX)*<sup>1</sup> é um *AEU* desenvolvido com o intuito de registrar os fluxos de conteúdo multimídia apresentados em sala de aula e disponibilizá-los posteriormente para alunos e professores [Ferreira et al. 2012, Araújo et al. 2013]. Por meio de seu uso, é possível fazer a captura, armazenamento, acesso e extensão das mídias geradas em ambientes educacionais instrumentados e contribuir com os processos de ensino e aprendizagem de usuários que utilizam essa tecnologia no cotidiano. Para que essas atividades aconteçam de maneira transparente, o sistema atualmente conta com duas salas de aula equipadas com dispositivos computacionais (tais como microfones, lousas digitais, câmeras e projetores multimídia), localizadas na Faculdade de Computação da Universidade Federal de Uberlândia (FACOM/UFU).

Demandando modificações mínimas na maneira com que as aulas convencionais são lecionadas, o *CX* emprega recursos da *UbiComp* para auxiliar tanto professores, enquanto realizam a captura das aulas, quanto alunos, durante atividades de acesso ao conteúdo capturado. Para isso, o sistema conta com componentes de *hardware* e *software* especializados para realizar a gravação das atividades educacionais, sincronizar automaticamente os fluxos de mídia concebidos e disponibilizar esse conteúdo por meio de uma interface de acesso *Web*, cujas telas podem ser observadas na Figura 1.

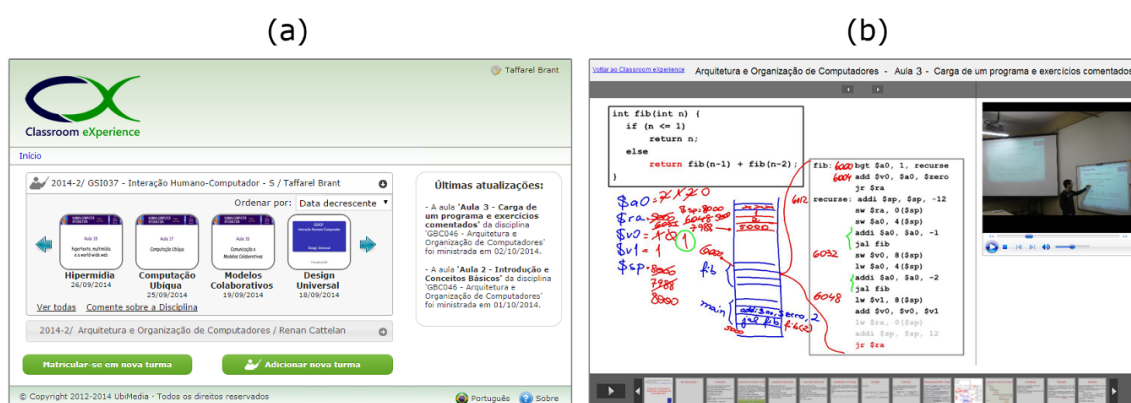


Figura 1. Interface *Web* do *CX*: (a) tela principal e (b) tela de aula capturada.

Ao fazerem *login* no sistema, os usuários são direcionados para a tela principal (Figura 1(a)), na qual é possível, para um professor, adicionar uma nova turma e, para os alunos, matricularem-se nas turmas já cadastradas no sistema. Além disso, esta página

<sup>1</sup><http://cx.facom.ufu.br/>

exibe as últimas atualizações que aconteceram no *CX*, tais como aulas capturadas recentemente e avaliações registradas pelos professores – como provas, trabalhos, exercícios e seminários. Ao selecionarem uma aula específica, os usuários devem escolher em qual formato de apresentação o conteúdo capturado será exibido. No *CX*, atualmente há três tipos de formato de apresentação: somente *slides*, somente vídeo e completo. Caso selecione a primeira opção, o usuário será direcionado para uma página contendo os *slides* utilizados pelo professor durante uma sessão de captura, já com as anotações feitas nessas mídias. A segunda opção apresentará apenas o vídeo de uma aula capturada pelo sistema e a terceira exibirá ambos os fluxos de mídia, conforme a Figura 1(b).

### 3. Material e Métodos

Para esta pesquisa, foram utilizados dados provenientes de oito turmas que cursaram disciplinas da grade curricular dos cursos de graduação da FACOM/UFU. Dessas, quatro não tiveram contato com a plataforma educacional *CX* e quatro utilizaram o sistema normalmente no decorrer do semestre letivo. Objetivando compreender os estudantes dos cursos de bacharelado em Sistemas de Informação e Ciência da Computação, foram selecionadas disciplinas que ambos os cursos possuem em comum, de modo a haver turmas mistas com quantidades diversificadas de alunos de cada curso.

As oito amostras selecionadas foram compostas por  $N$  observações da variável sob análise. Tendo em vista que cada amostra compreendeu uma turma de alunos matriculados numa disciplina, o tamanho das amostras não se manteve fixo e variou de 26 a 44 estudantes. Como a variável estudada nesta pesquisa foi o desempenho dos alunos, notas dos estudantes foram coletadas e, para cada uma das amostras, realizou-se combinações aleatorizadas das observações (reamostragens) para formar subamostras de vários tamanhos a partir da amostra original. O método *Bootstrapping* [Efron 1979] foi utilizado para a realização da reamostragem, de modo que para cada subamostra de tamanho  $n$  originada de uma amostra de tamanho  $N$ , foram realizadas 2000 reamostragens para todo  $n \leq N$ . Em seguida, para cada um dos conjuntos de 2000 subamostras de mesmo tamanho resultantes, realizou-se o cálculo da média, ( $\bar{x}$ ), variância ( $s^2$ ), desvio padrão ( $s$ ) e coeficiente de variação ( $CV$ ), além de um intervalo de confiança ( $IC$ ) de 95% para essas medidas.

Para a realização do cálculo do tamanho ótimo de amostra por meio do *MMCM*, representou-se a relação entre o  $CV$  e o tamanho da amostra empregando-se a equação de regressão:

$$CV_x = aX^{-b} \quad (1)$$

na qual:  $CV_x$  é o coeficiente de variação entre as subamostras de tamanho  $n$ ;  $a$  é o coeficiente de variação de amostras de tamanho unitário;  $X$  é o tamanho das subamostras; e  $b$  é o coeficiente de regressão [Barros e Tavares 1995].

Também foram calculados os coeficientes de determinação ( $R^2$ ) das amostras e representou-se a relação entre os  $CV$ s e os tamanhos das subamostras de maneira gráfica em eixos cartesianos, nos quais o eixo  $y$  representou o  $CV$  e o eixo  $x$  retratou o intervalo dos tamanhos de amostra. Após estabelecer as estimativas dos  $CV$ s de todas as subamostras de cada turma analisada, calculou-se o valor referente ao ponto da abcissa no qual ocorre a máxima curvatura do modelo empregado, correspondente ao tamanho ótimo de amostra, denominado  $X_{MC}$  e obtido por meio da fórmula:

$$X_{MC} = [a^2b^2(2b + 1)/b + 2]^{(1/2b+2)} \quad (2)$$

na qual:  $X_{MC}$  é o valor exato da abcissa que corresponde ao ponto de máxima curvatura do modelo;  $a$  é o coeficiente de variação de amostras de tamanho unitário; e  $b$  é o coeficiente de regressão [Meier e Lessman 1971].

Pelo fato da fórmula 2 resultar num valor exato, realizou-se o arredondamento de cada  $X_{MC}$  obtido, respeitando a regra adotada pela [ABNT 1977]. Além disso, conforme [Meier e Lessman 1971], os tamanhos ótimos resultantes a partir do MMCM devem ser expressos numa medida denominada *Unidade Básica (UB)*, que demanda transformações quando uma *UB* compreende um conjunto de observações maior que um. Para esta pesquisa, cada *UB* representou exatamente um aluno, de modo a não ser necessário realizar outras transformações nos tamanhos obtidos além de arredondamentos.

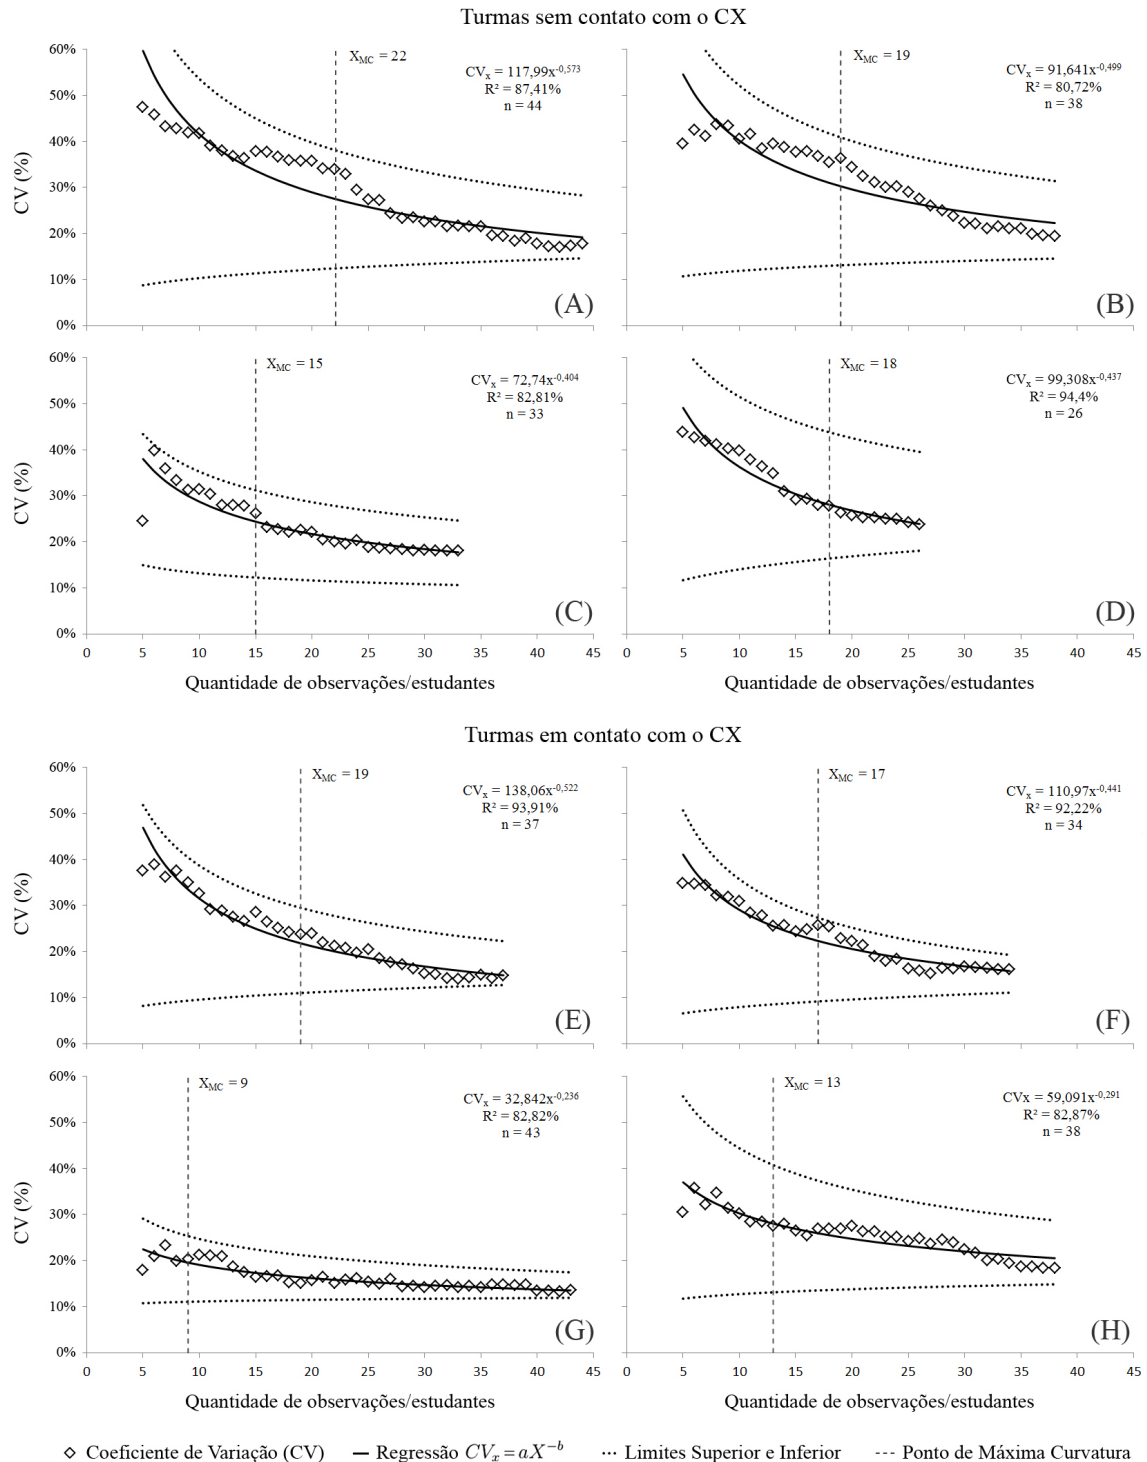
#### 4. Resultados e Discussões

As observações das subamostras de tamanho muito pequeno ( $n < 5$ ) apresentaram dispersões de caráter inconclusivo. Tal resultado já era esperado, pois necessita-se que haja uma quantidade mínima de observações para ser possível estudar a distribuição das amostras. Deste modo, estabeleceu-se um limite mínimo de cinco observações para o início da análise dos *CVs* em cada uma das turmas examinadas. Essa análise se estendeu até o tamanho original das amostras selecionadas para o estudo.

A Figura 2 apresenta os oito eixos cartesianos correspondentes às amostras estudadas, sendo os quatro primeiros referentes às turmas que não tiveram contato com o *CX* e os demais relativos às turmas que empregaram o sistema. O *CV* exato de cada tamanho de subamostra foi representado nos eixos junto à equação de regressão de potência que indicou a tendência dos dados obtidos. Também calcularam-se os limites superiores e inferiores dos *CVs*, mas optou-se por representá-los já aplicados ao modelo, almejando demonstrar os pontos máximos e mínimos que o *CV* seria capaz de alcançar em cada subamostra sob um *IC* de 95%.

De modo geral, os valores dos *CVs* diminuíram ao passo que o tamanho das subamostras aumentou. O tamanho ótimo de amostra entre as quatro turmas que não tiveram contato com o *CX* variou entre 15 e 22 estudantes, enquanto nas turmas que empregaram o sistema durante os semestres letivos a estimativa obtida foi de 9 a 19 alunos. Com base nesses resultados, torna-se possível compreender que as turmas que utilizaram o *AEU* no decorrer dos semestres letivos tenderam a apresentar um tamanho ótimo inferior ao obtido nas que não tiveram contato com a tecnologia. Em função disso, infere-se que o tamanho ótimo de amostra capaz de analisar o desempenho de alunos em contato com tecnologias educacionais seja de 20 indivíduos, ao passo que para se investigar turmas que não utilizam sistemas educacionais, no mínimo sejam observados 25 estudantes.

A partir da análise das linhas de tendência presentes nos eixos da Figura 2, também foi possível perceber que a diminuição do *CV* não foi proporcional ao aumento dos tamanhos das subamostras, acentuando-se no início e tornando-se mais próxima à estabilidade em quantidades elevadas de observações. Caso as amostras analisadas tivessem sido ainda maiores, pressupõe-se que se alcançaria um ponto em que as linhas de tendência dos limites superior e inferior e do *CV* se interceptariam. Por meio desse comportamento, deduz-se que o aumento do tamanho das amostras apenas se manteve conveniente até determinado ponto, a partir do qual o emprego de quantidades maiores de observações não foi compensado, em função dos baixos ganhos em precisão experimental.



**Figura 2. Relações entre os coeficientes de variação e os tamanhos de subamostras para a variável desempenho em oito turmas de cursos de computação.**

Por fim, o  $R^2$  alcançado nas análises manteve-se acima de 80% em todas as amostras estudadas, o que demonstra boa precisão de ajuste das regressões e alta confiabilidade nas estimativas obtidas. O coeficiente de regressão  $b$ , capaz de representar a variabilidade dos experimentos sob análise, variou de 0,404 a 0,573 entre as turmas que não tiveram contato com o CX e de 0,236 a 0,522 nas turmas que o empregaram durante os semestres. Tendo por base que o  $b$  poderia variar de zero a um e indicar, respectivamente, baixo e alto nível de variabilidade das amostras, é possível perceber que as turmas que utilizaram o sistema apresentaram uma menor variabilidade média e, conseqüentemente, maior homogeneidade entre as notas obtidas pelos alunos no decorrer da pesquisa. De modo a corroborar essa informação, o maior  $b$  observado entre as turmas foi obtido na amostra A (0,573), que fez parte do grupo de turmas que não tiveram contato com o CX e apresentou o maior  $X_{MC}$  (22) entre as turmas analisadas. Em contrapartida, a amostra G, analisada entre as demais que também tiveram contato com o sistema, obteve o menor  $b$  (0,236) e  $X_{MC}$  (9) dentre as turmas investigadas nesta pesquisa.

## 5. Trabalhos Relacionados

A determinação do tamanho ótimo de amostra é uma temática de pesquisa relevante, pois permite o entendimento da real dimensão da variabilidade de experimentos e a estimação de um tamanho mínimo necessário para se garantir a confiabilidade de resultados obtidos [Meier e Lessman 1971]. Na literatura, é possível encontrar pesquisas que determinam essa estimativa em circunstâncias precisas, tais como para melhorar o processo de classificação em mineração de dados, ajustando-se curvas de aprendizagem para determinar o tamanho de conjuntos de treinamento [Last 2009], ou para estimar assintoticamente um tamanho ótimo que permita a detecção de mudanças repentinas na estatística de processos [Pelkowitz e Schwarts 1987].

Além disso, também há trabalhos que abordam a determinação de tamanhos ótimos de amostra para o treinamento de redes neurais [Cui et al. 2004], alocação de recursos para múltiplas atividades concorrentes [Eu 1989] e minimização do custo total de fabricação de circuitos digitais *ULSI* [Pham 1992]. Na vertente de pesquisa em sistemas *Web*, um tamanho de amostra de cinco usuários foi inicialmente proposto por [Nielsen 2000], que justificou tal quantidade como suficiente para se compreender 80% dos problemas de usabilidade em interfaces. No entanto, esse tamanho foi readequado com a criação da *Regra de  $10 \pm 2$*  usuários [Hwang e Salvendy 2010] e, em seguida, ambos foram contestados por [Schmettow 2012], que demonstrou que a estimativa de tamanhos de amostra não era algo trivial, havendo fatores diversos que causariam a variabilidade dos dados sob análise e sendo importante se atentar a esses detalhes para que os resultados não subestimassem a característica investigada.

No âmbito educacional, tamanhos de amostra específicos para diferentes tipos de análise foram apresentados por [Mertens 2014]. Dentre as indicações, recomendou-se o uso de pelo menos 64 participantes em testes de correlação, 15 observações em testes de regressão múltipla e um mínimo de 51 elementos para pesquisas comparativas. Tais tamanhos foram obtidos por meio de análises do poder de testes estatísticos e os resultados são, na verdade, médias dos valores resultantes nos testes realizados para cada uma dessas vertentes [Onwuegbuzie e Collins 2007]. Ainda nesse escopo, [Slavin e Smith 2009]

observaram que o tamanho das amostras apresenta uma correlação inversa com o efeito estudado em revisões sistemáticas na área educacional. Revisões que abordam quantidades menores de trabalhos sobre determinada temática acabam se mostrando enviesadas e relatando efeitos mais positivos do que os trabalhos que compreendem quantidades mais abrangentes de conteúdo e de fato representam o universo pesquisado.

Tais trabalhos fortalecem a relevância de se estimar tamanhos ótimos de amostra para ser possível compreender as populações investigadas em nível satisfatório. Pesquisas nessa vertente, no entanto, não são frequentes no âmbito computacional, devido a possibilidade de algumas áreas simularem seus estudos em quantidades elevadas para atestarem suas hipóteses. No entanto, trabalhos que envolvem elementos externos, como análises que observam fatores humanos, apresentam a necessidade de se determinar um tamanho ótimo de amostra em função da impossibilidade de se trabalhar frequentemente com quantidades muito elevadas de indivíduos. Em função disso, este trabalho se destaca dos observados na literatura ao demonstrar uma estimativa robusta para se analisar o desempenho acadêmico de estudantes em contato com tecnologias educacionais, tais como os *AEUs*. Tendo em vista que a quantidade de discentes em turmas presenciais de cursos de graduação é, muitas vezes, reduzida, mostra-se necessário estimar tamanhos de amostra capazes de compreender a variabilidade das populações de alunos sob análise e permitir que resultados confiáveis sejam alcançados por pesquisadores que trabalham nesta vertente científica.

## 6. Conclusões

Este trabalho objetivou estimar o tamanho ótimo de amostra para a análise do desempenho acadêmico de estudantes em cursos de graduação da área computacional. Determinou-se um tamanho ótimo de 25 alunos para se analisar esta variável em turmas que não utilizam tecnologias educacionais no cotidiano e de 20 estudantes para turmas que possuem contato com sistemas educacionais durante os semestres letivos.

Por meio da análise das linhas de tendência geradas, percebeu-se que a diminuição dos *CVs* não apresentou um comportamento proporcional à elevação dos tamanhos das amostras, intensificando-se no começo e tornando-se estável à medida que as amostras aumentaram. Em função disso, é possível concluir que a elevação do tamanho das amostras se manteve conveniente apenas até certo ponto, a partir do qual o emprego de quantidades maiores de observações não foi compensado devido ao ganho reduzido em precisão experimental. Para uma análise ainda mais robusta acerca do desempenho de estudantes, recomenda-se empregar amostras de pelo menos 25 observações em ambas as vertentes demonstradas, de modo a ser possível abranger a variabilidade das turmas sob análise e se realizar uma investigação capaz de compreender as populações apresentadas.

Tais resultados se mostram relevantes para pesquisas que fazem uso de fatores humanos, pois demonstram que amostras com quantidades reduzidas de observações são capazes de compreender grande parte do comportamento da variável sob análise. Devido aos custos e obstáculos existentes para se trabalhar com um elevado número de indivíduos em contextos diversificados, o cálculo de um tamanho ótimo de amostra se revela como uma alternativa robusta para se obter alto índice de confiabilidade em inferências obtidas a partir de análises em contextos mais reduzidos.



## Agradecimentos

Os autores gostariam de agradecer às agências de pesquisa FAPEMIG, CAPES e CNPq, ao PET/SESu/MEC e ao Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais (IFSULDEMINAS) o apoio concedido a este trabalho.

## Referências

- ABNT (1977). NBR 5891: Regras de Arredondamento na Numeração Decimal. *NBR 4: Norma Brasileira Probatória*, 1:1.
- Aihua, Z. (2010). Study of Ubiquitous Learning Environment Based on Ubiquitous Computing. In *Proc. of the 3<sup>rd</sup> IEEE U-Media*, pages 136–138, Jinhua, CN. IEEE.
- Araújo, R. D., Brant-Ribeiro, T., Cattelan, R. G., Amo, S. A. e Ferreira, H. N. (2013). Personalization of Interactive Digital Media in Ubiquitous Educational Environments. In *Proc. of the IEEE SMC'13*, pages 3955–3960, Manchester, UK. IEEE.
- Barneveld, A. V., Arnold, K. E. e Campbell, J. P. (2012). Analytics in Higher Education: Establishing a Common Language. *EDUCAUSE Learning Initiative*, 1:1 – 11.
- Barros, I. d. e Tavares, M. (1995). Estimativa do Tamanho Ótimo de Parcelas Experimentais Através de Cálculos Algébricos. *Bragantia*, 54(1):209–215.
- Chatti, M. A., Lukarov, V., Thüs, H., Muslim, A., Yousef, F. A. M., Wahid, U., Greven, C., Chakrabarti, A. e Schroeder, U. (2014). Learning Analytics: Challenges and Future Research Directions. *eled*, 10(1).
- Cui, Y.-J., Davis, S., Cheng, C.-K. e Bai, X. (2004). A Study of Sample Size with Neural Network. In *Proc. of the ICMLC'04*, volume 6, pages 3444–3448 vol.6.
- Dickson, P. E., Warshow, D. I., Goebel, A. C., Roache, C. C. e Adrion, W. R. (2012). Student Reactions to Classroom Lecture Capture. In *Proc. of the 17<sup>th</sup> ACM ITiCSE*, pages 144–149. ACM.
- Efron, B. (1979). Bootstrap Methods: Another Look at the Jackknife. *The Annals of Statistics*, 7(1):1–26.
- Eu, J. H. (1989). A Sampling Approach to Real-Time Performance Monitoring of Digital Transmission Systems. In *Proc. of the 8<sup>th</sup> IPCC*, pages 207–211.
- Ferreira, H. N. M., Araújo, R. D., de Amo, S. e Cattelan, R. G. (2012). Classroom Experience: A Platform for Multimedia Capture and Access in Instrumented Educational Environments. In *Proc. of the 2012 SBSC*, pages 59–64. IEEE.
- Ferreira, S. A. e Andrade, A. (2014). Learning Analytics in Practice: Development and Implementation of A Support System to the Management of the Teaching Activity. *International Journal of Education and Practice*, 2(4):67–95.
- Gomez, K. A. e Gomez, A. A. (1984). *Statistical Procedures for Agricultural Research*. John Wiley & Sons, New York, USA, 2<sup>nd</sup> edition.
- Hwang, W. e Salvendy, G. (2010). Number of People Required for Usability Evaluation: The  $10 \pm 2$  Rule. *Communications of the ACM*, 53(5):130–133.
- Internet World Stats (2014). World Internet User Statistics and World Population Stats; 2014. URL: <http://www.internetworldstats.com/stats.htm>. Acessado em 17/07/2015.

- Kinshuk e Graf, S. (2012). Ubiquitous Learning. In *Encyclopedia of the Sciences of Learning*, pages 3361–3363. Springer USA.
- Last, M. (2009). Improving Data Mining Utility with Projective Sampling. In *Proc. of the 15<sup>th</sup> ACM KDD*, pages 487–496, New York, NY. ACM.
- Lessman, K. J. e Atkins, R. E. (1963). Optimum Plot Size and Relative Efficiency of Lattice Designs for Grain Sorghum Yield Tests. *Crop science*, 3(6):477–481.
- Meier, V. D. e Lessman, K. J. (1971). Estimation of Optimum Field Plot Shape and Size for Testing Yield in *Crambe abyssinica* Hochst. *Crop Science*, 11(5):648–650.
- Mertens, D. (2014). *Research and Evaluation in Education and Psychology: Integrating Diversity With Quantitative, Qualitative, and Mixed Methods*. SAGE Publications, 4<sup>th</sup> edition.
- Nielsen, J. (2000). Why you Only Need to Test With 5 Users. *Jakob Nielsen's Alertbox*.
- Onwuegbuzie, A. J. e Collins, K. M. (2007). A Typology of Mixed Methods Sampling Designs in Social Science Research. *Qualitative Report*, 12(2):281–316.
- Pelkowitz, L. e Schwartz, S. (1987). Asymptotically Optimum Sample Size for Quickest Detection. *IEEE Trans. Aerosp. Electron. Syst.*, AES-23(2):263–272.
- Pham, H. (1992). Optimal Design of Life Testing for ULSI Circuit Manufacturing. *IEEE Trans. Semiconduct. Manufact.*, 5(1):68–70.
- Schmettow, M. (2012). Sample Size in Usability Studies. *Commun. ACM*, 55(4):64–70.
- Settle, A., Dettori, L. e Davidson, M. J. (2011). Does Lecture Capture Make a Difference for Students in Traditional Classrooms. In *Proc. of the ITiCSE'11*, pages 78–82. ACM.
- Siemens, G. e Long, P. (2011). Penetrating the Fog: Analytics in Learning and Education. *EDUCAUSE review*, 46(5):30.
- Silva, R. d., Xavier, A., Leite, H. G. e Pires, I. E. (2003). Determinação do Tamanho Ótimo da Parcela Experimental pelos Métodos da Máxima Curvatura Modificado, do Coeficiente de Correlação Intraclasse e da Análise Visual em Testes Clonais de Eucalipto. *Revista Árvore*, 27(5):669–676.
- Slavin, R. e Smith, D. (2009). The Relationship Between Sample Sizes and Effect Sizes in Systematic Reviews in Education. *Educational Evaluation and Policy Analysis*, 31(4):500–506.
- Steel, R., Torrie, J. e Dickey, D. (1997). *Principles and Procedures of Statistics: A Biometrical Approach*. McGraw-Hill series in probability and statistics. McGraw-Hill, New York, USA, 3<sup>rd</sup> edition.
- Weiser, M. (1991). The Computer for the 21<sup>st</sup> Century. *Sci. Am.*, 265(3):66–75.
- Wieling, M. B. e Hofman, W. H. A. (2010). The Impact of Online Video Lecture Recordings and Automated Feedback on Student Performance. *Computers & Education*, 54(4):992–998.
- Zhao, X., Wan, X. e Okamoto, T. (2010). Adaptive Content Delivery in Ubiquitous Learning Environments. In *Proc. of the 6<sup>th</sup> IEEE WMUTE*, pages 19–26.