

Desafios e Oportunidades do Design no Contexto dos Grandes Dados: o Caso da *Learning Analytics*

I.R. Pinheiro^{a,b,c}, E. Merino^c e L.S.Gomes^c

^a pinheiro_ir@yahoo.com.br

^b Centro Universitário de Brusque - UNIFEBE

^c Universidade Federal de Santa Catarina

Resumo

No campo do design, pouco ainda se pesquisa a respeito de como diferenças quantitativas podem se transformar em ganhos qualitativos e isso se mostra um empecilho para a atuação dos próprios designers em projetos que requerem o equacionamento de Grandes Dados, como é o caso das emergentes oportunidades em *learning analytics*. Para sanar tal déficit, este artigo tem como objetivo, então, introduzir, por meio de uma revisão crítica da literatura, o contexto dos Grandes Dados aos profissionais da área do design. O texto, além de se voltar para a compilação de evidências de que a análise de Grandes Dados acadêmicos já torna possível intervenções mais precisas e objetivas em atributos qualitativos do design, também enfoca a necessidade de ações efetivas por parte desses profissionais para sanar problemas relacionados ao envolvimento dos usuários e à inteligibilidade das informações. Dentro da área específica de *learning analytics*, as quatro principais oportunidades discernidas para o design são as melhoras em ergonomia de interface, a gestão de projetos interdisciplinares, a intermediação de interesses dos diferentes stakeholders e, certamente, a aplicação massiva do design instrucional. Espera-se estimular a atuação de designers nos contextos que hoje mais exigem técnicas holísticas para a síntese de problemas.

Palavras-chave: Design, Grandes Dados, Learning Analytics, Análise, Síntese.

Challenges and Opportunities for the Design in the Context of Big Data: The Case of Learning Analytics

Abstract

In design, there is still few research on how quantitative differences turn into qualitative gains in a variety of projects, and it can be perceived as a step back in the designers' opportunities of action whenever it is needed Big Data equation, as such is the case of *learning analytics*. In order to remedy that, this article aims at introducing the Big Data context itself to design professionals through a critical review of the literature. The text, in addition to compile evidence that Big Data analysis of academic records already makes possible to make more accurate and objective interventions in qualitative design attributes, also covers the need of effective action to solve general problems related to users involvement and information intelligibility. Within the specific area of *learning analytics*, the four main opportunities discerned for the design are the improvements in interface ergonomics, the management of interdisciplinary projects, the mediation of different stakeholders' interests, and most certainly the massive application of instructional design. Hopefully the content will stimulate the engagement of designers in such contexts that nowadays require mostly holistic techniques for the synthesis of problems.

Keywords: Design, Big Data, Learning Analytics, Analysis; Synthesis.

1. INTRODUÇÃO

No campo do design, muito se discute sobre como diferenças qualitativas são capazes de se converter em vantagens quantitativas, a chamada sinergia, mas pouco ainda se fala ou se pesquisa a respeito de como as diferenças quantitativas, sobretudo no volume, na velocidade e na variedade de dados disponíveis, se transformam em ganhos qualitativos para os grupos de interesses em uma imensidão de projetos. Nisso, não se sabe, por exemplo, como os mais de 3 bilhões de comentários diários no Facebook tem alterado as tendências de consumo de uma miríade de usuários; não se sabe de que forma a logística das cerca de 267 milhões de transações diárias efetuadas no Wal-Mart poderia ser utilizada para

melhorar a qualidade de vida dos funcionários dessa rede de lojas; e também não se sabe quais motivações guiam os comportamentos fraudulentos detectados pelo sistema automatizado da FICO, que investiga pelo menos 2,1 bilhões de contas ao redor do mundo [1]. A única coisa que se sabe ao certo é que o contexto dos Grandes Dados já é uma realidade e que esse novo paradigma oferece desafios e oportunidades singulares para todos os profissionais voltados para a criação de valor e a definição dos próprios padrões de qualidade em domínios, até então, complexos demais para o seu adequado equacionamento projetual.

Conforme o *Horizon Report* de 2014 [2], um desses domínios de atuação que presentemente necessitam de

intervenção em design é, sem dúvida alguma, o ramo da educação. A análise de Grandes Dados acadêmicos, também conhecida como *learning analytics*, apesar de ser uma das principais tendências para a aceleração da adoção de tecnologias no ensino superior nos próximos anos, ainda requer a integração dos grupos de interesse universitário para a delimitação de critérios de formação e aprovação coerentes [3], a definição das variáveis comportamentais e dos atributos individuais mais adequados para prever o desempenho futuro dos estudantes [4] e, também, melhores plataformas de visualização para a correta compreensão e utilização das informações de acompanhamento [2,5]. Sem esses avanços em gerenciamento de projetos interdisciplinares, em design instrucional e em ergonomia de interfaces, não é possível criar sistemas de aviso que antecipem estados críticos de desempenho estudantil, dificilmente cativar-se-á o interesse de alunos e professores por essa nova tecnologia e nem extrair-se-á o máximo de informações dos Grandes Dados acadêmicos já compilados.

Este artigo tem como objetivo, então, introduzir o contexto dos Grandes Dados aos profissionais da área do design, uma vez que as ferramentas disponíveis nesse ambiente, finalmente, oferecem meios de operacionalizar e, por conseguinte, de tangenciar os ditos fenômenos complexos, como a aprendizagem, mas seu potencial projetual ainda não foi devidamente explorado. Por meio de uma revisão crítica da literatura, de natureza monográfica e exploratória [6], o texto volta-se para a compilação de evidências de que a análise de Grandes Dados acadêmicos já torna possível intervenções mais precisas e objetivas em certos atributos qualitativos do design, porém, que também ainda são necessárias ações efetivas para sanar problemas específicos relacionados ao envolvimento dos usuários e à inteligibilidade das informações. Espera-se, com isso, estimular a atuação de designers no contexto dos Grandes Dados, o qual, exemplificado pela área de *learning analytics*, tende se tornar um nicho crescente de profissionais munidos com técnicas holísticas para a resolução criativa de tais problemas.

O texto, como um todo, organiza-se da seguinte forma. Na primeira seção, define-se o contexto dos Grandes Dados e apresenta-se as suas principais repercussões, sobretudo qualitativas, tanto no paradigma científico quanto o paradigma cultural da humanidade. Na segunda, discutem-se os fundamentos e os procedimentos da análise de Grandes Dados, cujo foco é a transformação de correlações em mecanismos de predições. Na terceira, introduz-se a emergente área de *learning analytics* como caso ilustrativo do potencial dos Grandes Dados para tornar tangíveis os fenômenos, até então, considerados complexos demais para serem abordados de maneira precisa, objetiva e eficaz por profissionais dedicados às suas propriedades qualitativas. E, por fim, na quarta seção, listam-se os mais aparentes desafios e oportunidades do design nesse novo contexto de atuação rico em evidências materiais, mas ainda pobre em ações projetuais. Ademais, conclui-se com uma breve reflexão sobre a necessidade dos designers se familiarizarem com toda uma variedade de novos mecanismos de análise quantitativa de dados, não apenas para sustentarem o holismo em seu exercício profissional, mas, também para melhor compreenderem as mudanças de valor que já estão ocorrendo no mundo atual.

2. O CONTEXTO DOS GRANDES DADOS

O uso de Grandes Dados é uma das tendências mais proeminentes para as pesquisas, para o mercado e para a

administração pública da atualidade. Conforme Chen e Zhang [1], além desse mesmo uso constar nas listas de *Top 10 Strategic Technology Trends for 2013* e de *Top 10 Critical Tech Trends for the Next Five Years*, vários campos do conhecimento, como a física, a economia e a sociologia já estão sendo revolucionados pelo equacionamento da tremenda quantidade, velocidade e diversidade de dados prontamente disponíveis para análise. De forma geral, tem-se por hábito, então, definir o próprio conceito de Grandes Dados, justamente, pela soma dessas três características, a chamada explicação de 3Vs (volume, velocidade e variedade) [7], mas também existem outras explicações, as quais costumam inserir um quarto V, que pode indicar valor, veracidade ou virtualidade [8].

Diferentemente do que se possa intuir de imediato, um dos principais fatores de destaque dos Grandes Dados não é, porém, o seu impacto quantitativo, mas sim a sua repercussão qualitativa. O atual aumento exponencial na capacidade de criação de dados dos seres humanos, que em 2011 chegou à marca de 2,5 quintilhões de bytes por dia [9], tem gerado inúmeros benefícios às instituições públicas e privadas, dentre os quais pode-se citar o aumento na eficiência operacional, a melhora no direcionamento estratégico, o melhor atendimento ao consumidor, uma maior facilidade para o desenvolvimento de novos produtos, a identificação de novos mercados, a redução dos procedimentos burocráticos e a simplificação das regulamentações governamentais [1]. Tudo isso está alterando fundamentalmente tanto o paradigma científico, quanto o paradigma cultural da humanidade.

Em relação à ciência, a computação intensiva em Grandes Dados já é, por exemplo, considerada o quarto paradigma científico, diferenciando-se da ciência empírica, da ciência teórica e da ciência de simulações [10,11]. Os Grandes Dados, mais que resolverem de maneira adequada o até então dilema do tripé dos métodos de pesquisa [12], o qual impedia que os estudos fossem simultaneamente controlados, generalizáveis e realistas (Fig. 1), também dispensam o recurso aos traços latentes em Modelos de Equação Estrutural, o que possibilita a interpretação de fenômenos complexos como sistemas verdadeiramente holísticos e não hierárquicos [13,14]. Nisso, reduz-se a diferença entre as intervenções de campo e de laboratório, atinge-se uma escala desproporcionalmente maior nos experimentos e, ainda, operacionaliza-se de maneira mais adequada as teorias utilizadas.

Já em relação à cultura, os Grandes Dados tem alterado sobretudo a percepção individual a respeito dos conceitos de conectividade, de privacidade e de efetividade. O constante e massivo uso dos vestígios comportamentais deixados em redes sociais, em plataformas governamentais e em inúmeras produções pessoais para definir padrões de comportamento, especialmente em relação ao consumo, além de facilitar e personalizar a comunicação e as trocas entre sujeitos e entre sujeitos e instituições, está modificando profundamente os limites considerados normais em termos de territorialidade e de produtividade [12]. Ao mesmo tempo em que se aceita, sem grandes preocupações, cada vez mais que se colete dados pessoais em *browsers* da internet e em sensores populacionais, exige-se igualmente mais eficiência por parte dos prestadores de serviços como contraparte desse novo contrato social [1]. Destarte, os Grandes Dados não agem somente como um catalisador das práticas coletivas tradicionais, mas também oferecem um contexto diferenciado em que as escolhas e as decisões baseadas em evidências (*evidence-based* ou *data-driven*), ao contrário

daquelas baseadas em mitos, genialidades ou mesmo inferências prévias de especialistas, são visivelmente mais

proveitosas tanto para os indivíduos isoladamente, quanto para as suas sociedades como um todo [3,12].

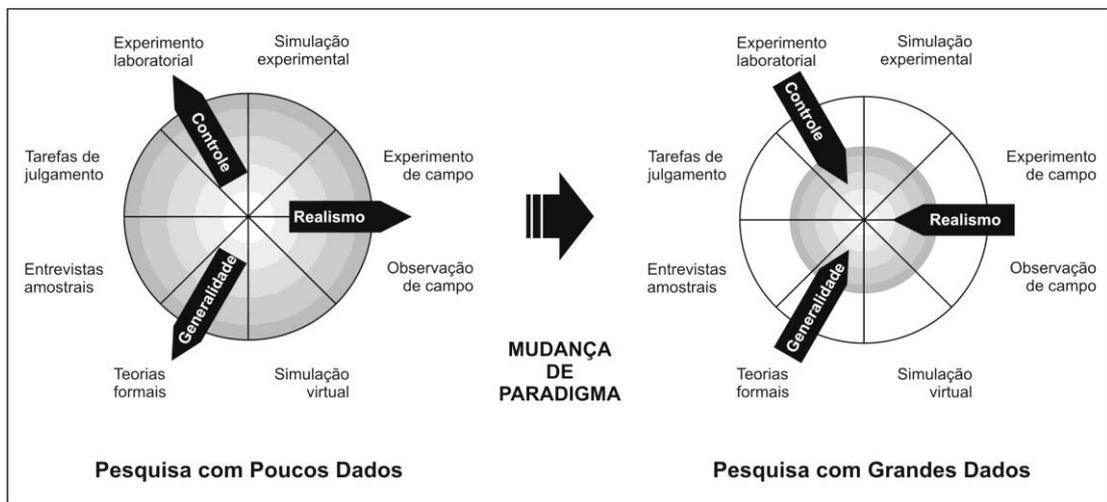


Figura 1: Mudança de paradigma científico provocado pelos Grandes Dados.

Fonte: Autor, baseado em Chang, Kauffman e Kwon [12].

Acredita-se que as principais causas dessas mudanças de paradigma foram os avanços nas tecnologia da informação (TI), a ampla difusão do conhecimento interdisciplinar, a melhora nas estratégias competitivas empresariais e o aumento na velocidade da própria competição em mercados abertos [12]. Tudo isso, após convergir para a prática da mineração de dados (*data mining*) em supermercados nos anos 90, teria se condensado em novos estudos e aplicações voltadas para a predição de comportamentos complexos, como o tráfego portuário, a valorização de ações, a compra casada em sites da internet e a criação de novas amizades, os quais até então eram caóticos demais para serem compreendidos e manipulados de maneira precisa na ausência de Grandes Dados [12,15]. Não existe um número exato que defina a extensão máxima de um conjunto de dados antes que ele seja considerado Grande, uma vez que o critério está constantemente mudando com o passar do tempo, mas é consenso que os Grandes Dados referem-se a conjuntos de tamanho tal que a sua captura, a sua curadoria, a sua pesquisa, o seu compartilhamento, o seu armazenamento, a sua transferência, e, principalmente, a sua análise esteja além da capacidade de processamento em tempo viável de softwares comuns [16].

Nisso, é pertinente ressaltar que o maior desafio presente no contexto dos Grandes Dados é a análise do conteúdo coletado, e não a aquisição desse mesmo conteúdo, até porque a produção de dados cresce de maneira mais rápida que a capacidade de armazená-los [1]. No campo da educação, Siemens [3] aponta, por exemplo, que a combinação dos bancos de dados disponibilizados por redes sociais, sistemas de gerenciamento universitário e sistemas de acompanhamento acadêmico já oferecem conjuntos de tamanho significativo, mas que ainda não se sabe como extrair informações úteis desse compilado aparentemente desordenado. Não se insere, então, os Vs de verdade ou de valor na definição básica dos Grandes Dados senão por meio de sua análise, pois evidências quaisquer, mesmo que agrupadas, só se convertem em saber quando são contextualizadas e, assim, ganham sentido.

3. A ANÁLISE DE GRANDES DADOS

O processo geral de análise, definido de maneira simplificada, parece à primeira vista um tanto paradoxal. Trata-se da decomposição de elementos complexos em suas partes

constituintes, para que com isso se obtenha uma compreensão melhor do funcionamento, do sentido ou da razão de existir do todo original [17]. Assim sendo, a análise só existe em função da síntese; a quebra, em função da estruturação; e as técnicas de objetivação, correlação e apresentação, em função das capacidades humanas de generalização, previsão e compreensão intuitiva. Nisso, em última instância, pode-se dizer inclusive, nas palavras de George Siemens [3], que "[...] tudo o que há de importante na análise, acontece somente após a análise".

O emprego desse processo como meio de se gerar compreensões amplas e, por vezes, holísticas é, contudo, uma alternativa bastante lógica. Ao se isolar uma unidade qualquer, além de se perceber com mais nitidez o relacionamento dessa mesma unidade com as demais partes constituintes de seu todo, torna-se possível investigar o efeito de sua ausência na configuração global, o qual, de outra maneira, sempre poderia ser confundido pela ação de outras determinantes do sistema inicial. Destarte, não é paradoxal dizer que a análise consiste, basicamente, do uso da divisão como meio de se compreender a união, pois a maneira mais eficiente de se investigar a emergência de fenômenos únicos com variância multidimensional é tentar refutar a hipótese de que não há relacionamento entre duas partes desse todo quando uma delas é mantida constante. Esta é, aliás, a própria lógica utilizada no método científico.

Nisso, antes de ser uma atividade específica, uma tecnologia, um processo de transformação ou, mesmo, um conjunto de capacidades, a análise de dados é um movimento de caráter cultural [18]. Esse movimento, baseado na filosofia de resolução de problemas por meio da estruturação científica de evidências, em oposição à resolução de problemas fundamentada em mitos, opiniões ou relatos anedóticos, tem como cerne a ideia de se cumprir propósitos práticos através do uso de estratégias racionais. O movimento em si, então, é desencadeado pelo processo iterativo decorrente da descoberta de evidências que, ao indicarem caminhos para a resolução de problemas pontuais, melhoram as próprias capacidades de descobrir mais evidências, gerando um ciclo virtuoso centrado em ações ideais. Tal movimento centrípeto, mais que atuar como centro gravitacional de valores como a transparência, a integridade e a excelência, alinha as capacidades necessárias para se tomar decisões consistentes, comprometidas e cheias

de propósito, o que, por sua vez, propulsiona a inércia cultural [18].

O resultado final de qualquer análise bem sucedida sempre é, portanto, a transformação de dados em novas percepções a respeito do funcionamento do sistema fracionado, ou a transformação de dados em decisões capazes de otimizar o relacionamento humano com esse mesmo sistema investigado [18]. Enquanto as novas percepções atuam no sentido de ampliar a quantidade de alternativas viáveis para a manipulação de um elemento complexo, as decisões caracterizam-se como avaliações qualitativas de cada uma dessas alternativas, o que possibilita melhores ações. Assim sendo, como decorrência das análises, pode-se gerar conhecimento a respeito do que já aconteceu (relatórios), do que está acontecendo (alertas) e do que do que possivelmente irá acontecer (extrapolações), e, também, a respeito de como e de por que algo aconteceu (explicações), a respeito de quais são as melhores ações a serem tomadas (recomendações) e a respeito das repercussões mais prováveis de serem geradas (predições), o que corresponde a uma matriz de informações e intuições sobre o passado o presente e o futuro (Fig. 2) [19].

	Passado	Presente	Futuro
Intuições	Relatórios	Alertas	Extrapolações
Informações	Explicações	Recomendações	Predições

Figura 2: Matriz de conhecimentos gerados pelas análises.
Fonte: Autor, baseado em Cooper [19].

Todo esse conhecimento proveniente das análises depende, porém, do quanto o seu movimento inicial é capaz de afetar os três fatores que mais estimulam o seu uso, ditos a quantidade de dados disponíveis, a maturidade das técnicas de trabalho e o nível de competitividade ambiental [19]. Os dados, primeiramente, são o objeto das análises. Quanto maior for a quantidade dessa matéria prima, mais abrangentes e significativos podem ser os resultados das análises, uma vez que possibilita-se a captura de padrões de relacionamento mais sutis e indiretos. Já as técnicas são os meios de se realizar as análises. Quanto mais maduros forem os seus procedimentos metodológicos, maior será o potencial de conversão de quantidades em qualidades, uma vez que percebe-se e controla-se melhor o relacionamento entre os dados. A competitividade, por fim, é o objetivo das análises. Quanto mais acirrada for a competitividade, maior será a necessidade de controle e de eficiência, uma vez que também mais aumenta-se a velocidade das transformações no contexto organizacional. Poucos dados, técnicas simples e baixa competitividade são capazes, em geral, de oferecer conhecimento somente sobre o passado e sobre parcelas do presente, mas Grandes Dados, técnicas complexas e alta competitividade são capazes de oferecer um amplo conhecimento sobre o presente e o futuro também (Fig. 3).

Assim sendo, o estado da arte da análise de dados consiste de avaliar o passado para estimar os melhores e os piores cenários futuros, para que com isso possa-se intervir de maneira eficiente e eficaz em qualquer que seja o

contexto que estimulou o próprio processamento de dados [19]. Até então, as comunidades mais envolvidas com esse tipo de análise de ponta são aquelas formadas por profissionais da área de inteligência empresarial, de mineração de dados, de web análise, de pesquisa operacional, de biomedicina, de astronomia, de inteligência artificial, de análise de redes e de *learning analytics* [1,19]. Certamente, o que mais diferencia essas áreas das demais é o emprego de Grandes Dados, já que a lógica das técnicas utilizadas para, praticamente, qualquer tipo de análise é de domínio público e as necessidades organizacionais são virtualmente infinitas, mas o manejo adequado de grandes volumes de evidências materiais ainda exige recursos e infraestrutura acessíveis somente aos nichos que já possuem grandes mercados comerciais [1,18].

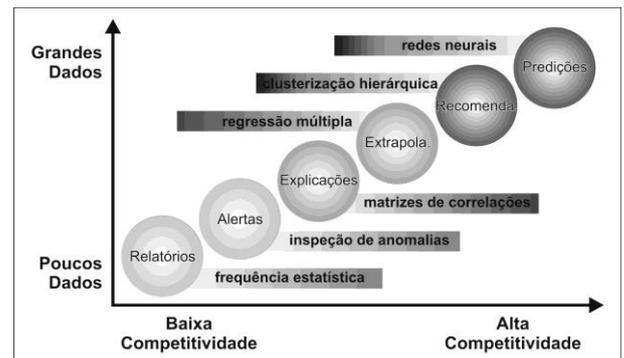


Figura 3: Fatores que estimulam o uso da análise de dados.
Fonte: Autor, baseado em Siemens [3].

A característica da análise de Grandes Dados que a torna singular é, portanto, a necessidade de algoritmos e equipamentos de ponta capazes de paralelizar em larga escala o processamento de dados para que, assim, seja possível realizar tarefas computacionais complexas em um tempo comercialmente viável [1]. As atuais plataformas utilizadas para esse tipo de tarefa normalmente concentram-se em 3 classes: 1) as ferramentas de processamento sequencial (*batch*), como o Apache Hadoop, o Dryad e o Tableau; 2) as ferramentas de processamento em tempo real (*stream*), como o Storm, o S4 e o Splunk; e 3) as ferramentas de análise interativas (*interactive*), como o Dremel e o Apache Drill. Apesar de suas peculiaridade, o que se percebe em comum em todas essas ferramentas é a boa arquitetura de informação, o amplo suporte a diferentes métodos de análise, a capacidade de personalizar o tamanho de entrada dos dados, a coordenação entre o processamento e as unidades de dados e, sobretudo, o processamento e armazenamento distribuído para computação em memória RAM [1].

A perfeita analogia para a análise de Grandes Dados costuma ser, então, o próprio cérebro humano [1]. Sua eficiência, além de resultar do processo iterativo de seleção de comportamentos que exigem alto grau de inteligência, requer, simplesmente, a distribuição e a paralelização ótima de unidades de processamento de baixa capacidade e velocidade, os neurônios. Por meio desse tipo de estrutura, mesmo as técnicas analíticas mais complexas não geram sobrecarga, pois, na medida em que mais correlações são necessárias para uma determinada tarefa, mais partições de informações também tornam-se integradas através de sua ativação sincrônica, gerando resultados de natureza ubíqua e não concatenada. Nisso, em suma, a análise de Grandes Dados pode ser compreendida, fundamentalmente, como uma estratégia evolutiva para se calcular complexos padrões

3) os artefatos estudantis, que oferecem poder preditivo e capacidade de intervenção medianos. Exemplos do primeiro tipo de variável são a idade, o gênero, a etnia, as notas do currículo escolar progressivo, a quantidade de cursos prévios, o status financeiro e os traços de personalidade. Exemplos do segundo tipo de variável são o número de acessos à página de acompanhamento acadêmico, a quantidade de tempo gasto no site do curso, o número de postagens no fórum de discussão do curso e as notas das avaliações em sala de aula. E, por fim, exemplos do terceiro tipo de variável são os principais tópicos abordados pelas redações, o conteúdo das discussões em sala e em ambientes virtuais, o tipo de produção independente realizada extraclasses e os afetos declarados pelos próprios alunos.

Nenhum desses tipos de variáveis é necessariamente melhor que os outros, mas cada um deles é mais adequado para guiar decisões de diferentes naturezas no âmbito educacional [5]. Enquanto os indicadores prévios são especialmente propícios para equacionar os processos de seleção e, portanto, para inferir sobre a composição ótima das turmas, os vestígios comportamentais servem sobretudo para hierarquizar as práticas pedagógicas mais eficientes, o que possibilita selecionar bons materiais didáticos, e os artefatos estudantis para explorar os mecanismos de motivação individual, o que possibilita formular grades curriculares corretamente alinhadas com cada aluno. Nisso, é necessário a soma dos três tipos de variáveis, normalmente na forma de múltiplas linhas de regressão, para se orientar com precisão uma instituição em seus próximos ciclos de atuação, uma vez que só assim compõem-se uma visão realmente holística do próprio significado do aprendizado.

Um típico processo de *learning analytics* não captura, então, o aprendizado dos alunos diretamente em nível sináptico, mas sim por meio dos principais padrões de comportamento associados aos diferentes níveis de desenvolvimento individual e coletivo, as chamadas "rubricas" [4,25]. A despeito da existência de algumas críticas relacionadas à abrangência dessas definições operacionais, as quais ainda se restringem à diversidade de práticas adotadas pelos alunos, ao tempo empregado em cada uma dessas atividades, ao conteúdo semântico mais procurado, à estrutura dos discursos produzidos e ao progresso exibido, pesquisas em pequena escala já demonstraram correlações de até 0,95 entre elas e o desempenho estudantil final em determinados cursos [4,21,28]. Assim, mesmo que novos estudos ainda sejam necessários para corroborar a adequabilidade das rubricas, pode-se afirmar que o processo de operacionalização empregado em *learning analytics*, pelo menos, já oferece meios de se monitorar e guiar o desempenho estudantil em suas atuais avaliações formais.

Em um futuro não tão distante, entretanto, a tendência é que todas as demais promessas realizadas pelos profissionais desta área também se cumpram, já que inúmeras outras pesquisas com Grandes Dados educacionais estão sendo atualmente conduzidas. Nesse sentido, além da conversão de definições constituintes em definições operacionais cada vez mais adequadas, os tópicos mais presentes em *learning analytics* são os métodos de extração de significado dos dados, a implementação de sistemas informatizados em faculdades e demais instituições, a ética e o direito à privacidade na coleta de dados, a adequabilidade dos processos de análise aos sistemas de gerenciamento acadêmicos, o design instrucional, a modelagem preditiva, as forças geratrizes da evasão escolar e o projeto de cursos adaptados às avaliações por rubricas [4]. Os resultados dessas pesquisas, ao esclarecerem os próximos desafios e oportunidades de atuação em *learning analytics*,

continuarão, então, impulsionando os mais recentes avanços na área da educação.

4.1 Desafios e oportunidades do design em *learning analytics*

A área de *learning analytics* é um bom exemplo de como o contexto dos Grandes Dados, sobretudo nas ciências humanas, econômicas e sociais aplicadas, ainda possui inúmeros desafios a serem superados. Apesar de muito já se ter avançado no desenvolvimento de algoritmos e equipamentos capazes de paralelizar em larga escala o processamento de dados [19,28] e, também, nas tarefas de quantificar e equacionar os complexos fenômenos presentes no cenário educacional [27,29], relativamente pouco se progrediu, de fato, na conversão da miríade de correlações geradas em melhores decisões, em melhores critérios de sucesso, em melhores estruturas curriculares ou, mesmo, em um melhor conhecimento de causa [27,28,30,31]. Nisso, dentre os seus principais desafios ainda a serem superados, pode-se certamente citar a valoração das inúmeras ações pedagógicas idealizadas, a interpretação dos inúmeros grupos de interesses envolvidos, a estruturação das inúmeras atividades didáticas elaboradas e a exibição das inúmeras variáveis acadêmicas analisadas.

Se expostos dessa forma, percebe-se, então, que os desafios em *learning analytics*, aparentemente, não dizem respeito à análise propriamente dita dos dados educacionais, mas sim à síntese das inúmeras informações levantadas em ações pontuais. Em cada etapa do típico processo de trabalho com Grandes Dados (Fig. 4), são necessários projetos não apenas para transformar qualidades em quantidades, como já se tem feito por profissionais com domínio em estatística, em engenharia e em computação, mas também projetos para traduzir e reunificar essas mesmas quantidades em novas qualidades. É preciso conferir um caráter dialético ao processo de *learning analytics*, no qual cada ciclo de atividade é composto igualmente por análises e sínteses (Fig. 5). É preciso, portanto, que também haja a intervenção de profissionais com domínio em técnicas projetivas holísticas, estas voltadas mais diretamente para a resolução criativa de problemas por meio da integração e da contextualização de informações. É preciso, basicamente, que os designers encarem os desafios em *learning analytics* como oportunidades para realizar suas atuações.

Dentre as oportunidades de trabalho para os designers em *learning analytics*, um primeiro tópico digno de menção é, então, a ergonomia de interfaces com foco na arquitetura da informação. Vários softwares, como o SNAPP, o LOCO-Analyst, o ROLE e o Signals, estão surgindo para suprir a demanda comercial por ferramentas dedicadas à análise de Grandes Dados educacionais, mas, de forma geral, a exibição das informações coletadas e analisadas ainda é bastante deficiente para os usuários-finais [32]. Assim sendo, é preciso que se crie novas interfaces que permitam os gestores, os educadores e os alunos examinarem facilmente os dados disponíveis sem que eles tenham que dominar processos técnicos alheios às suas práticas usuais [3,26]. Tais interfaces, mais que combinar harmoniosamente um conjunto de gráficos em monitores de acompanhamento das atividades coletivas, devem funcionar como filtros dos padrões de relacionamento existentes entre as variáveis acadêmicas investigadas, uma vez que só assim torna-se inteligível o fluxo de acontecimentos no sistema educacional e, por conseguinte, obtém-se conhecimento sobre as verdadeiras causas do processo de aprendizagem individual [5,23].

Outra oportunidade do design em *learning analytics* é, por sua vez, o ordenamento e o alinhamento das inúmeras

ações pedagógicas imaginadas para favorecer melhores tomadas de decisão a nível institucional. Essa atividade, normalmente vinculada ao domínio do gerenciamento de projetos interdisciplinares [33], tem como objetivo principal discernir previamente os diferentes valores percebidos na implementação ou na manutenção das possíveis estratégias de intervenção no cenário educacional, uma vez que o impacto delas no aprendizado normalmente não se verifica

de imediato e nem de maneira direta [25]. Nisso, faz-se necessário esforços não apenas para se evitar a utilização dos Grandes Dados analisados de maneira leviana ou simplificada o que sustenta argumentos puramente políticos ou opinativos [4], mas também, e sobretudo, para integrar toda a instituição nos cursos de ação planejados, o que promove a eficiência sistêmica e a participação democrática [5].

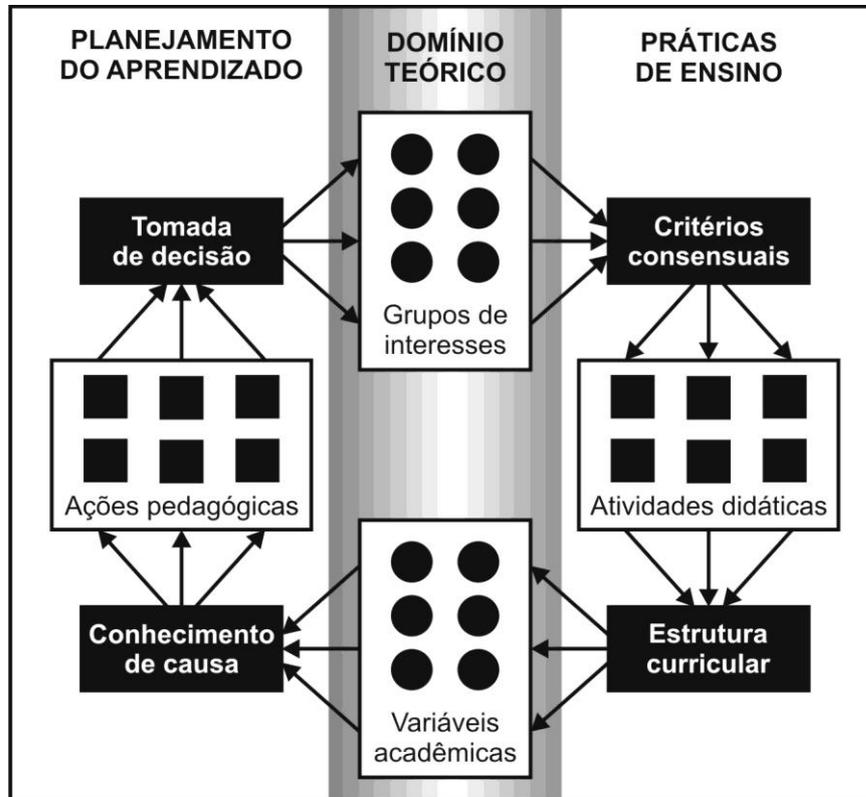


Figura 5: Ciclo de análises e sínteses em *learning analytics*.

Fonte: Autor

Já a terceira oportunidade de trabalho para os designers em *learning analytics* também envolve a integração de diferentes grupos de interesse, porém, estes mais externos que internos às instituições de ensino. O aprendizado, por quase sempre se tratar de um meio e não de um fim, simplesmente não pode ser considerado um sistema fechado em si [3]. Todo o trabalho com educação só existe em função de algum propósito social, comercial ou individual e, portanto, deve-se integrar e interpretar os diferentes interesses do governo, dos empresários, dos sindicatos, dos pesquisadores, dos familiares e dos próprios alunos para a definição dos resultados esperados e, então, o estabelecimento de critérios de sucesso consensuais [23,26]. Para tal, faz-se necessário a atuação de agentes do conhecimento para garantir que todas as partes sejam devidamente ouvidas e valorizadas frente às demais [34], bem como para mediar os conflitos de interesses pelo recurso às evidências materiais disponíveis e não somente pelo voto ou pelo exercício da autoridade [27,28].

Por fim, a quarta nítida oportunidade em *learning analytics* exibida em seu ciclo de análises e sínteses é o próprio design instrucional. Com base em todas as evidências coletadas e em todas as informações geradas, pode-se estruturar currículos personalizados, o que chega a aumentar o desempenho dos alunos em até 2 desvios padrão [5,32], e ordenar os conteúdos conforme a sua dificuldade, o que

fomenta a intenção de adoção das plataformas de análise pelos professores [26]. Já existem vários sistemas eletrônicos para a estruturação de cursos presenciais e não presenciais, como o Moodle e o Blackboard, mas a sua atual capacidade de personalização ainda é bastante limitada e pouco, ou nada, das avaliações se converte em instrumentos de *feedback* imediato do aproveitamento em sala [26]. Nisso, deve-se trabalhar não apenas para alinhar as inúmeras atividades didáticas no portfólio dos instrutores e das instituições, mas também para inserir de maneira perspicaz e eficaz as medições formais como parte das práticas de ensino habituais [26,27].

Desse modo, aproveitar-se-ia o trabalho dos designers em todo o ciclo de atividades presentes na análise de Grandes Dados educacionais, as quais tiram proveito de suas capacidades de sintetizar informações em conhecimentos, valores em decisões, interesses em critérios e práticas didáticas avulsas em estruturas curriculares otimizadas. Como um todo, essas oportunidades de atuação requerem de tais profissionais, além de suas habituais competências projetuais, somente o domínio de técnicas analíticas básicas, como a leitura e a interpretação de dados estatísticos e o mapeamento de redes de variáveis sociais. Uma vez que a tendência é empregar cada vez mais as ferramentas de *learning analytics* como meios de propiciar a evolução da educação [3], espera-se que os próprios projetistas industriais

também se adaptem a essas oportunidades de atuação e, então, que o domínio dos novos mecanismos de análise quantitativa ganhem espaço em sua formação.

5. CONSIDERAÇÕES FINAIS

O contexto dos Grandes Dados já é uma realidade e a atual revolução que vem ocorrendo no campo da educação é a maior prova disto. Todo profissional que anseia por novas áreas de atuação pode, então, se engajar em uma vasta gama de atividades envolvendo tanto a análise quanto a síntese de informação, mas, para tal, é essencial manter-se atualizado e familiarizado com as modernas técnicas e ferramentas de cálculo estatístico e de quantificação. Uma vez que os designers já dominam, por formação, técnicas de valoração, de interpretação, de estruturação e de exibição de dados, esse requisito, aparenta, portanto, ser o único desafio significativo ainda presente entre as atuais oportunidades em *learning analytics*, por exemplo, e a sua ampla contratação.

Mais que ganhar um novo espaço comercial, o principal benefício do conhecimento científico a respeito dos procedimentos de análise e objetivação para o design é, entretanto, a manutenção do holismo em seu exercício profissional. O surgimento de funcionalidades digitais capazes de suportar a produção ubíqua de dados, como o Google Drive e o Dropbox, tornam cada vez mais difícil, quicá impossível, o equacionamento global das variáveis envolvidas em projetos de comunicação em larga escala somente com base na intuição. Nisso, para evitar a obsolescência dos seus próprios métodos de trabalho, os quais teriam amplitude limitada no contexto dos Grandes Dados, é preciso que os projetistas industriais aprendam a quantificar antes de criar.

Futuras pesquisas envolvendo o design no contexto dos Grandes Dados devem corroborar, então, com a constatação de que assim como a síntese é sempre o fim das análises, a análise pode sempre ser compreendida como um recurso ótimo para o início das sínteses complexas. Destarte, os designers tornar-se-iam capazes não somente de interpretar e arquitetar informações, mas também de processá-las, desempenhando o papel de "*data wrangler*", ao se mover livremente da descrição de fatos à realização de boas inferências subjetivas em um *continuum* de comunicação [23]. Tal atuação, compatível com as atuais demandas nos campos da economia, da psicologia, da sociologia e, certamente, da educação, tende aproximar os fenômenos invisíveis aos sentidos da população e, com isso, criar valor com base nos atributos impossíveis de serem percebidos somente pelo recurso isolado à sua quantificação ou à sua qualificação.

REFERÊNCIAS

- [1]. Chen, C., and Zhang, C. Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*, 275, (2014), 314–347.
- [2]. Johnson, L., Adams Becker, S., Estrada, V., and Freeman, A. NMC Horizon Report: 2014 Higher Education Edition. The New Media Consortium, Austin, Texas, 2014.
- [3]. Siemens, G. Leaping the Chasm: Moving from Buzzwords to Implementation of Learning Analytics. EDUCAUSE Live! Webinar. 2012 [acesso em 14 ago 2014]; Disponível em: <http://www.educause.edu/library/resources/leaping-chasm-moving-buzzwords-implementation-learning-analytics>.
- [4]. Diaz, V., and Brown, M. Learning analytics: A report on the ELI focus session. EDUCAUSE Learning Initiative. 2012 [acesso em 14 ago 2014]; Disponível em: <http://www.educause.edu/library/resources/learning-analytics-report-eli-focus-session>.
- [5]. Brown, M. Learning analytics: moving from concept to practice. EDUCAUSE Learning Initiative. 2012 [acesso em 14 ago 2014]; Disponível em: <http://www.educause.edu/library/resources/learning-analytics-moving-concept-practice>.
- [6]. Marconi, M., and Lakatos, E. Fundamentos de metodologia científica. Atlas, São Paulo, 2007.
- [7]. Laney, D. 3D data management: Controlling data volume, velocity and variety. *Application Delivery Strategies - Meta Group*, (2001), 949.
- [8]. Zikopoulos, P., Eaton, C., DeRoos, D., Deutsch, T., and Lapis, G. Understanding Big Data: Analytics for Enterprise Class Hadoop and Streaming Data. McGraw Hill Professional, New York, 2011.
- [9]. Hilbert, M., and López, P. The world's technological capacity to store, communicate, and compute information. *Science*, 332, 6025 (2011), 60–65.
- [10]. Bell, G., Hey, T., and Szalay, A. Beyond the data deluge. *Science*, 323, 5919 (2009), 1297–1298.
- [11]. Hey, T., Tansley, S., and Tolle, K. The fourth paradigm: Data-intensive scientific discovery. Microsoft Research, Washington, 2009.
- [12]. Chang, R., Kauffman, R., and Kwon, Y. Understanding the paradigm shift to computational social science in the presence of big data. *Decision Support Systems*, 63, (2014), 67–80.
- [13]. Borsboom, D. Psychometric perspectives on diagnostic systems. *Journal of Clinical Psychology*, 64, 9 (2008), 1089–1108.
- [14]. Van der Maas, H., Dolan, C., Grasman, R., Wicherts, J., Huizenga, H., and Raijmakers, M. A dynamical model of general intelligence: The positive manifold of intelligence by mutualism. *Psychological Review*, 113, 4 (2006), 842–861.
- [15]. Siegel, E. Predictive analytics: The power to predict who will click, buy, lie, or die. John Wiley & Sons, New Jersey, 2013.
- [16]. Snijders, C., Matzat, U., and Reips, U. "Big Data": Big gaps of knowledge in the field of internet science. *International Journal of Internet Science*, 7, 1 (2012), 1–5.
- [17]. Beaney, M. Analysis. The Stanford Encyclopedia of Philosophy. 2012 [acesso em 14 ago 2014]; Disponível em: <http://plato.stanford.edu/entries/analysis/>.
- [18]. Holsapple, C., Lee-Post, A., and Pakath, R. A unified foundation for business analytics. *Decision Support Systems*, (2014), press.
- [19]. Cooper, A. A brief history of analytics. *JISC CETIS Analytics Series*, 1, 9 (2012) [acesso em 14 ago 2014]; Disponível em: <http://publications.cetis.ac.uk/2012/529>.
- [20]. GSV Advisors. Education sector factbook 2012. 2012 [acesso em 14 ago 2014]; Disponível em: <http://www.educationindustry.org/assets/documents/KnowledgeCenterDocs/2012%20gsv%20education%20sector%20factbook.pdf>.
- [21]. Brown, M. Learning analytics: The coming third wave. EDUCAUSE Learning Initiative. 2011 [acesso em 14 ago 2014]; Disponível em: <http://www.educause.edu/library/resources/learning-analytics-coming-third-wave>.

- [22]. Ferguson, R. Learning analytics: Drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4, 5/6 (2012), 304–317.
- [23]. Powell, S., and MacNeill, S. Institutional Readiness for Analytics. *JISC CETIS Analytics Series*, 1, 8 (2012) [acesso em 14 ago 2014]; Disponível em: <http://publications.cetis.ac.uk/2012/527>.
- [24]. Fulantelli, G., Taibi, D., and Arrigo, M. A framework to support educational decision making in mobile learning. *Computers in Human Behavior*, (2014), press.
- [25]. Shum, S. Learning analytics. UNESCO Policy Brief. 2012 [acesso em 14 ago 2014]; Disponível em: <http://iite.unesco.org/publications/3214711/>.
- [26]. Ali, L., Asadi, M., Gasevic, D., Jovanovi, J., and Hatala, M. Factors influencing beliefs for adoption of a learning analytics tool: An empirical study. *Computers & Education*, 62, (2013), 130–148.
- [27]. Tempelaar, D., Rienties, B., and Giesbers, B. In search for the most informative data for feedback generation: Learning analytics in a data-rich context. *Computers in Human Behavior*, (2014), press.
- [28]. Friesen, N. Learning analytics: Readiness and rewards. *Canadian Journal of Learning and Technology*, 39, 4 (2013), 1-12.
- [29]. Ali, L., Hatala, M., Gasevic, D., and Jovanovi, J. A qualitative evaluation of evolution of a learning analytics tool. *Computers & Education*, 58, (2012), 470–489.
- [30]. Patterson, R., Blaha, L., Grinstein, G., Liggett, K., Kaveney, D., Sheldon, K., Havig, P., and Moore, J. A human cognition framework for information visualization. *Computers & Graphics*, 42, (2014), 42–58.
- [31]. Yigitbasioglu, O., and Velcu, O. A review of dashboards in performance management: Implications for design and research. *International Journal of Accounting Information Systems*, 13, (2012), 41–59.
- [32]. EDUCAUSE. 7 things you should know about... First generation learning analytics. EDUCAUSE Learning Initiative. 2011 [acesso em 14 de ago 2014]; Disponível em: <https://www.educause.edu/library/resources/7-things-you-should-know-about-first-generation-learning-analytics>.
- [33]. Project Management Institute - PMI. *Guia PMBOK: Um guia do conhecimento em gerenciamento de projetos*. Saraiva, São Paulo, 2012.
- [34]. Bertola, P., and Teixeira, J. Design as a knowledge agent: How design as a knowledge process is embedded into organizations to foster innovation. *Design Studies*, 24, (2003), 181-194.