

# **INOVAÇÃO COM DADOS: A EXPERIÊNCIA DO USUÁRIO COM SISTEMAS BASEADOS EM INTELIGÊNCIA ARTIFICIAL**

## **DATA INNOVATION: USER EXPERIENCE WITH ARTIFICIAL INTELLIGENCE-BASED SYSTEMS**

*Cynthia Ruiz*<sup>1</sup>

*Manuela Quaresma*<sup>2</sup>

## Resumo

O objetivo deste artigo é refletir sobre as questões que envolvem as inovações baseadas em inteligência artificial, do ponto de vista do UX Design. Procuramos contextualizar o crescimento de conteúdo, os avanços tecnológicos e a valorização dos dados armazenados e processados em alta velocidade. Tratamos do processo de inovação e da experiência do usuário com interfaces baseadas em inteligência artificial, tecnologia em ascensão, porém com pouca maturidade no campo do Design. Foi realizada uma revisão bibliográfica para gerar reflexões em um artigo teórico. Desafios foram identificados para melhorar a experiência dos usuários com as interfaces baseadas em aprendizado de máquina.

**Palavras-chave:** Experiência do usuário; Inteligência Artificial; Aprendizado de Máquina; Tecnologia; Design

## Abstract

The purpose of this article is to reflect on the issues surrounding innovations based on artificial intelligence, from the point of view of UX Design. We seek to contextualize the growth of content, technological advances and the enhancement of data stored and processed at high speed. We deal with the innovation process and the user experience with interfaces based on artificial intelligence, technology on the rise, but with little maturity in the field of Design. A bibliographic review was carried out to generate reflections in a theoretical article. Challenges have been identified to improve the user experience with machine-based interfaces.

**Key-words:** User experience; Artificial intelligence; Machine Learning; Technology; Design

---

<sup>1</sup> cinthiaruiz@gmail.com

<sup>2</sup> mquaresma@puc-rio.br

## 1 INTRODUÇÃO

A internet é uma grande contribuição da tecnologia para a sociedade e colaborou muito para o rápido e exponencial crescimento do volume de conteúdo que temos hoje. A maneira como interagimos com o conteúdo muda com o passar do tempo, devido a diversos fatores, os quais alguns podemos identificar: 1. O avanço tecnológico permite que os usuários gerem mídia facilmente e um grande volume de dados seja armazenado e processado; 2. As pessoas têm mais acesso a diversos dispositivos digitais, pois são lançados no mercado uma grande variabilidade de tipos e marcas/ modelos de dispositivos, com preços mais baixos; 3. Os hábitos das pessoas mudam, influenciados pelos desejos e tarefas do mundo real; e 4. O conteúdo disponível para as pessoas aumenta em volume e variabilidade. Como consequência, a arquitetura de informação dos sistemas digitais sofre influência, pois precisa estar de acordo às novas necessidades da sociedade e modelo mental de seus usuários. Torna-se muito importante entregar o conteúdo que os usuários esperam de forma rápida, como será visto mais adiante.

O grande avanço tecnológico dos últimos anos permite o armazenamento de grande volume de dados e o processamento desses dados em alta velocidade. Em meio ao grande volume de conteúdo disponível para consumo das pessoas em geral, uma grande variedade de dados tem sido armazenada pelas empresas, no intuito de serem analisados e gerarem algum conhecimento que possa ser usado em prol dos negócios das empresas. Devido à grande valorização dos dados, seu potencial econômico e estratégico, os conceitos de *Big Data* e *Data Analytics* ganham força no mercado. O *Big Data* surge no princípio do século XXI, quando dados pessoais, de comportamento e atividades são armazenados em grande volume, variedade e velocidade.

Uma solução tecnológica que pode trazer muitos benefícios para o processo de análise de dados e muda muito o consumo das informações é a inclusão de algoritmos de *machine learning* (ML) – aprendizado de máquina, em inglês – e inteligência artificial (AI) nas interfaces digitais. A inteligência artificial das máquinas espelha-se na inteligência humana, para contribuir de maneira mais eficiente a atuação dos humanos. O aprendizado de máquina é um ramo da inteligência artificial que se propõe a aprender com dados e entregar predições para os humanos.

A inteligência artificial não é uma novidade, mas ganhou muita força nos últimos anos e ressurgiu como base de produtos inovadores, que impacta diretamente na experiência do usuário com as interfaces digitais. Abordaremos algumas análises de autores sobre o processo de inovação, envolvendo tecnologia e design. Embora a tradição nos mostre que as inovações geralmente são impulsionadas pela tecnologia, publicações apontam para a abordagem centrada no humano como uma maneira de atingir eficiência e satisfação com os produtos.

Este artigo propõe a reflexão sobre os impactos na experiência do usuário com a inserção de algoritmos de inteligência artificial em interfaces digitais. Para isso, argumentamos com base em diversas questões trazidas por outros autores e identificamos alguns desafios envolvendo a aplicação de inteligência artificial em interfaces digitais, do ponto de vista do campo de UX Design.

## 2 METODOLOGIA

Partindo da hipótese de que os sistemas baseados em Inteligência Artificial e Aprendizado de Máquina são desenvolvidos com foco no que a tecnologia pode entregar e não nas necessidades das pessoas, o que pode comprometer a experiência do usuário, foi realizada uma revisão bibliográfica com o objetivo de se compreender o estado da arte sobre essa relação dos sistemas inteligentes na experiência humana. Assim, a partir de bases de publicação acadêmicas, como por exemplo ScienceDirect, Google Scholar, Scopus, e outras publicações oriundas de empresas de tecnologia, diversos artigos e documentos que abordassem essa relação foram analisados e discutidos. Mais especificamente, foram estudados os seguintes temas:

- O aumento do conteúdo informacional e seu consumo pelos usuários de sistemas digitais;
- A relação dos avanços tecnológicos e fases da Internet com o volume de conteúdo informacional, para entender o histórico e impactos;
- A ansiedade da informação e a visão do usuário frente à carga informacional;
- Os conceitos de *Big Data* e Análise de Dados, e relação com o Aprendizado de Máquina;
- A valorização dos dados e as motivações de mercado;
- O processamento humano de informação e como o humano se relaciona com a informação;
- Os conceitos e aplicações de Inteligência Artificial e Aprendizado de Máquina;
- Os conceitos e aplicações de Inteligência Artificial Explicável;
- Os princípios da interação humana com os sistemas de AI;
- Sistemas de recomendação baseado em Aprendizado de Máquina;
- A experiência dos usuários com sistemas de recomendação baseados em Aprendizado de Máquina;
- O processo de inovação considerando as novas tecnologias e o papel do Design Centrado no Humano.

## 3 A INTERNET E O AUMENTO DO VOLUME DE CONTEÚDO

Criada inicialmente para fins militares e experimentada para fins acadêmicos, a internet teve um grande avanço no início da década de 90, quando atraiu interesses comerciais e finalmente foi aberta a todos, ampliando sua utilização, como relatado por Briggs e Burke (2006, p.302). A partir desse momento, todas as empresas querem ter sua presença online e criam seus websites para serem acessados pelos usuários da World Wide Web – WWW –, termo cunhado por Tim Burners-Lee em 1979. É também na década de 90 que surgem os primeiros jornais online brasileiros: JB e Globo. Segundo Sampaio (2007), entre 1994 e 1996, predominavam as páginas HTML estáticas. Foi a partir de 1996 que avanços tecnológicos possibilitaram a interação com o usuário mais

dinâmica, mas ainda com os usuários na posição de consumidores das informações, condição típica da Web 1.0. Com a virada do século, surge a Web 2.0, termo cunhado por Tim O'Reilly. "Na verdade, a Web 2.0 não representa nenhuma mudança tecnológica significativa, mas uma mudança de foco." (SAMPAIO, 2007, p.8). Os usuários saíram de uma posição passiva, na qual apenas consumiam informação, para uma posição ativa, na qual também são geradores de conteúdo com plataformas como por exemplo: blogs e redes sociais.

Rosenfeld et al. (2015) comentam que depois que a internet passou a ter a presença de interfaces alimentadas por conteúdo gerados por usuários, houve um crescimento exponencial do conteúdo. A informação nunca esteve tão abundante como hoje. Com o avanço tecnológico e variedade de dispositivos digitais, surgem mais maneiras de interagir com a informação. Jones e Endsley (2004) contextualizaram o momento como a "era da informação" e identificaram sinais de mudanças induzidas pela explosão das tecnologias da informação. As autoras alegam que constantemente somos bombardeados por mídia digital e impressa, além de todos os formulários e relatórios que circulam pelas empresas e comunicação ampliada pelas redes sociais.

Ainda na primeira década do século XXI, temos o surgimento da web semântica, a Web 3.0, com os dados armazenados na nuvem. O conteúdo pode ser personalizado e os mecanismos de busca são capazes de entregar diretamente informação relevante para os usuários.

Atualmente, temos acesso a informação com grande facilidade. Podemos acessar e gerar um grande volume de informação de qualquer lugar, através de dispositivos – móveis ou não – conectados a internet. Já está inserido em nosso cotidiano o consumo e a geração de conteúdo em grande velocidade, de forma barata e abundante. Com as ferramentas disponíveis em nossos dispositivos digitais, facilmente geramos, armazenamos e compartilhamos conteúdo em forma de texto, imagem, áudio e vídeo. Sabemos dos acontecimentos e nos comunicamos com grande parte do planeta com grande velocidade.

A WWW se tornou uma popular mídia global de informações através da qual seus usuários podem consumir e compartilhar dados por meios de dispositivos digitais conectados à Internet. Nesse contexto, é importante que um fornecedor de informação saiba focar, filtrar e comunicar o que é útil para o usuário. De acordo com Wurman (2001), o conteúdo transmitido 24 horas por dia por diversos canais faz com que as regras de navegação mudem e, conseqüentemente, o design da informação também muda. Segundo o autor, embora haja tanta informação, 99% não é significativo nem compreensível para as pessoas. Os designers têm um importante papel em tornar as buscas por conteúdo mais fáceis e navegação nos sistemas digitais mais fluidas, ao trabalharem na maneira de apresentar e organizar as informações, o que chamamos de Arquitetura da Informação, termo cunhado pelo próprio Wurman. O autor aponta ainda que, com a explosão de informações disponíveis na Internet, surgiram também novas indústrias, como mineração de dados e gerenciamento de conhecimento, que fazem uso das informações obtidas.

Passamos a vivenciar o problema de sobrecarga de informação, pois temos acesso a um volume muito grande de informação, vinda de diversos meios a todo momento. Constantemente, precisamos fazer buscas e escolhas nessa imensidão de conteúdo. Wurman (2001) explica que a ansiedade pela informação é produzida pela diferença cada vez maior entre o que entendemos e o que achamos que devemos entender,

quando as informações não nos dizem o que queremos saber. Segundo o autor, também ficamos ansiosos pelo fato de outras pessoas, como editores e produtores de conteúdo, controlarem nosso acesso à informação. Também ficamos ansiosos com as expectativas de outras pessoas sobre o que devemos saber.

Na segunda década do século XXI, vivenciamos o surgimento da Web 4.0, caracterizada pela simbiose entre humanos e máquinas, uma vez que os metadados são organizados e a inteligência artificial pode sugerir conteúdo ao usuário, baseando-se no aprendizado dos dados coletados referentes às buscas e interações do usuário. Segundo Nath e Iswary (2015), a Web 4.0 tem três principais conceitos: a técnica de compreensão da linguagem natural (NLU – *natural-language understanding*); a comunicação entre duas máquinas (M2M – *machine-to-machine*); e novo modelo de interface baseado em listas simples de resultados, mas com novo modelo de interação, personalizado, direcionado para o que o usuário precisa e automatizado.

Endsley e Jones (2004) apontam que apesar da abundância de informação, muitas pessoas se sentem menos informadas do que nunca, devido a lacuna entre o grande volume de dados produzidos e a capacidade humana de processá-los para chegar às informações reais necessárias. Para as autoras, parece ser ainda mais difícil descobrir o que realmente queremos ou precisamos saber. Elas afirmam que os problemas de sobrecarga de informações não são inevitáveis nem insuperáveis. A maneira mais eficaz de enfrentar a lacuna de informações seria aplicar o design centrado no usuário, não o design centrado na tecnologia.

Cada vez mais, temos dispositivos e interfaces digitais baseados em interação com inteligência artificial. Algoritmos de aprendizado de máquina executam previsões dos conteúdos que interessem aos usuários. A grande vantagem da inserção desses algoritmos nas interfaces digitais, no contexto da experiência do usuário, seria entregar conteúdo relevante para o usuário, sem que ele precisasse ter o trabalho de fazer escolhas. Esse cenário só é possível com grande armazenamento de dados e cálculos muito rápidos, mas para alcançar os objetivos de usabilidade, definidos pela ISO 9241-11 (1998) - eficácia, eficiência e satisfação. Entretanto, precisamos entender as necessidades dos usuários e programar de forma assertiva a máquina, com *input* humano, de forma a contemplar essas necessidades.

#### 4 BIG DATA E ANÁLISE DE DADOS

Devido ao avanço, contudo, das tecnologias de *hardware* e processamento, vivemos em uma era de grande valorização de dados. Tsihrintzis et al. (2019) afirmam que os dados no século XXI são como o petróleo no século XVIII. Os autores alegam que isso se deve aos bons dados que impulsionam a economia digital em todos os níveis, oferecendo novas oportunidades anteriormente indisponíveis. No entanto, dados tradicionalmente coletados, ou seja, índices econômicos, não são suficientes. Os autores apontam que todos os tipos de dados adicionais precisam ser coletados, armazenados, transmitidos, processados e convertidos em informação, conhecimento e, eventualmente, sabedoria.

Tsihrintzis et al. (2019) descrevem o termo “*Data Analytics*” (Análise de Dados) como sendo criado para descrever técnicas, softwares e sistemas de processamento especializados, com o objetivo de extrair informações de extensos conjuntos de dados e permitir que seus usuários tirem conclusões, tomem decisões informadas, apoiem

teorias científicas e gerenciem hipóteses. Com isso, a profissão do cientista de dados passou a ser, também, bastante valorizada, pois são esses profissionais que fazem todo esse processo de extrair, minerar e converter os dados em informação.

Assim, a inteligência de mercado aproveita a grande capacidade de geração e armazenamento de dados para traçar suas estratégias. Com isso, surge o conceito de análise de *Big Data* no princípio do século XXI, quando dados pessoais, de comportamento e atividades dos usuários de um determinado sistema podem ser utilizados. Para Minelli et al. (2013), a análise de *Big Data* é o resultado natural de quatro grandes tendências globais: 1. a Lei de Moore, que diz que a tecnologia sempre fica mais barata; 2. o aumento no uso da computação móvel, com *smartphones* e *tablets* pessoais; 3. o uso intenso das redes sociais; e 4. a criação do *cloud computing*, que libera as pessoas de terem seus próprios *hardware* e *software*, já que podem ser alugados ou licenciados. Dessa forma, o volume de dados transacionais aumentou muito em variedade e em velocidade, o que torna fundamental um gerenciamento de análise de dados. Nesse ponto, a tecnologia tem muito a agregar.

*Big Data* não trata apenas de volume, variedade e velocidade. O mais importante é saber quais dados serão úteis para a estratégia da empresa. Minelli et al. (2013, p.5) citam o renomado blogueiro da indústria, David Smith. Para ele, o verdadeiro desafio é identificar ou desenvolver métodos mais econômicos e confiáveis para extrair valor desse grande volume de dados.

Tsihrintzis et al. (2019) apontam que estamos no início da quarta Revolução Industrial, com a análise de dados emergindo com grande força, o que ocasiona mudanças em nossa rotina, no trabalho e nas relações humanas. Eles explicam que na primeira Revolução Industrial, dependíamos de carvão e água para acionar motores a vapor e óleo para acionar motores de combustão interna. Já a segunda Revolução Industrial, foi marcada pela linha de produção em massa e a terceira, pelos avanços em eletrônica e tecnologia da informação. Agora, a quarta Revolução Industrial é caracterizada por sinergias entre ciências e tecnologias físicas, digitais, biológicas e energéticas. Os autores preveem uma grande transformação na sociedade.

## 5 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

A informação disponibilizada pelo ambiente é processada através de uma série de sistemas de processamento humanos, como atenção, percepção e memória de curto prazo. O processamento de informação em pessoas e em computadores apresentam uma certa semelhança. O conhecimento é adquirido através de um processo de integração entre a forma de apresentação da informação e a mente do humano. Alcança-se a sabedoria, a inteligência, com a compreensão da mensagem através de experiências que só podem ser adquiridas individualmente.

A inteligência artificial, conhecida também pela sigla AI – oriunda do termo em língua inglesa *Artificial Intelligence* –, é a inteligência baseada na inteligência humana, manifestada pelas máquinas. Ela se espelha no processamento humano de informação, para possibilitar os computadores desempenharem tarefas as quais os humanos já realizam de forma automática, mas de maneira mais rápida e eficiente. Rouhiainen (2018) diz que a AI é a capacidade das máquinas de usar algoritmos para aprender com os dados e usar o que foi aprendido para tomar decisões como um ser humano faria. Sem a necessidade de descansos, as máquinas podem analisar grandes volumes de

informações de uma só vez e com muito mais assertividade do que os humanos.

A AI permite que as máquinas tenham uma capacidade de raciocínio, pois aplicam regras lógicas a um conjunto de dados disponíveis para chegar a uma conclusão. As máquinas aprendem com os erros e acertos apurando a eficácia de suas inferências e decisões, as quais implicam reconhecimento de padrões visuais, sensoriais ou de comportamento. Assim, Rouhiainen (2018) expõe que o aprendizado de máquina é uma das principais abordagens da inteligência artificial, com o qual máquinas têm a capacidade de aprender com os dados sem serem explicitamente programadas. O resultado são sugestões ou previsões para uma situação específica, o que permite uma experiência personalizada para cada usuário/indivíduo.

Holzinger (2018) comenta que o sucesso dos métodos estatísticos de aprendizado de máquina tornou o campo da Inteligência Artificial muito popular novamente, após um período no qual a AI esteve “adormecida”. O aprendizado de máquina é baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. Como a professora Gloria Phillips-Wren, Ph.D. da Loyola University Maryland, aponta no prefácio do livro “*Machine Learning Paradigms*” (Paradigmas do Aprendizado de Máquinas; TSIHRINTZIS et al., 2019), um dos primeiros artigos a utilizar o termo “*machine learning*”, foi o de Arthur Samuel, em 1959, intitulado “*Some Studies in Machine Learning Using the Game of Checkers*” (Alguns estudos no aprendizado de máquina usando jogo de damas), no qual ele conclui ser possível criar esquemas de aprendizado que superem as pessoas comuns e que podem ser aplicados a problemas da vida real.

A professora Gloria Phillips-Wren explica que o algoritmo de aprendizado usa o método supervisionado quando a máquina precisa criar um modelo baseado em dados de treinamento que inclua a resposta correta para minimizar o erro na previsão de novos dados. No aprendizado não supervisionados, os algoritmos procuram uma estrutura nos dados e formam grupos por semelhança. Existem ainda os métodos semi-supervisionado e por reforço. Os métodos usados no aprendizado de máquina estão sendo constantemente pesquisados e avaliados. Assim como modelos estatísticos, o objetivo do aprendizado de máquina é entender a estrutura dos dados – encaixar distribuições teóricas em dados bem entendidos.

Os conhecimentos do ML já estão presentes em muitas das interfaces inovadoras com as quais interagimos, como mecanismo de busca, links recomendados em comércio eletrônico, sistemas de streaming de áudio ou vídeo, detecção facial, detecção de fraudes fiscais, segurança de tecnologia da informação, automação de carros, aplicações médicas, etc. Rouhiainen (2018) argumenta que as tecnologias baseadas em AI já estão sendo usadas para ajudar os humanos em quase todas as áreas e à medida que continua a se desenvolver, mudará muitos aspectos da nossa vida.

Tecnologicamente, já se evoluiu muito e ainda há muito o que evoluir, mas precisamos pensar e nos posicionar em relação ao usuário operador desses sistemas humano-computador. Atualmente, as evoluções do ML /AI ainda estão muito voltadas para a própria tecnologia. Métodos de design podem ser empregados visando entender as necessidades reais dos usuários e melhorar sua experiência com os sistemas digitais baseados em AI.



## 6 INOVAÇÃO, TECNOLOGIA E DESIGN

Em um mundo competitivo e globalizado como o que vivemos atualmente, empreendedores almejam alcançar o sucesso com soluções inovadoras, as quais tenham grande impacto na sociedade e no mercado. O difícil é saber que problema resolver e como, seja criando um produto totalmente novo, evoluindo um já existente, ou até mesmo adaptando algo a novos significados.

Norman (2010) aponta que observando as principais descobertas conceituais com grandes impactos na sociedade e pequenas melhorias básicas, conclui que a pesquisa em design é adequada para melhorar produtos existentes, mas inútil no processo de criação de inovações. Ele separa os avanços em duas categorias: conceitual, que seria relativo à inovação, e incremental, relativo a melhorias. Já a teoria de Verganti (2011) tem pontos em comum com os argumentos de Norman (2010), aqui supracitados. Para os autores, o design possibilita a inovação incremental, focando em melhorar a interface para usuário, com diferencial, boas ideias e recursos que são rapidamente imitados e obsoletos.

Norman (2010) diz ainda que, embora tenhamos a tendência de acreditar que as descobertas conceituais se originem do levantamento detalhado das necessidades humanas, especialmente as ocultas, não é o que ocorre na prática. As inovações seriam, na verdade, impulsionadas pelo desenvolvimento de novas tecnologias, as quais inspiram os tecnólogos a inventar coisas, simplesmente porque querem provar sua capacidade. Com o passar do tempo, as invenções seriam testadas no mundo comercial, suas aplicações evoluiriam e a necessidade se desenvolveria, podendo até tornar-se essenciais. O autor alerta que a maioria das invenções falham, mas as que obtêm sucesso mudam nossas vidas. Nye (2006) aponta que os seres humanos redefinem continuamente suas necessidades, querendo sempre mais e que, muitas vezes, a necessidade não é a origem da invenção. Nesses casos, ocorre o oposto: a invenção origina a necessidade. Os seres humanos encontram novos usos para uma ferramenta, a qual existe, então, antes do problema que ela irá resolver.

Verganti (2011) compactua da visão de Norman (2010) apoiando-se na contribuição de Dosi (1982), a qual sugere que qualquer inovação implica na compreensão de tecnologias e mercados. As inovações tecnológicas radicais teriam impulso tecnológico, enquanto as inovações incrementais nos paradigmas tecnológicos existentes seriam motivadas pelas necessidades percebidas do mercado.

Para Verganti (2011), a conexão entre design e inovação, seria em relação aos significados dos produtos e serviços. O autor se refere ao entendimento das razões psicológicas e culturais pelas quais as pessoas usam um produto, as quais podem ser uma motivação individual ou social: “A motivação individual está ligada ao significado psicológico e emocional: o que sinto intimamente quando uso um produto. A motivação social está ligada ao significado simbólico e cultural: o que o produto diz sobre mim para os outros.” (VERGANTI, 2011, p.384)

Ainda segundo Verganti (2011), a concorrência no mercado é impulsionada pelo significado dos produtos, fato reconhecido por empresas e estudiosos. As pessoas compram e usam produtos motivadas pelas suas funcionalidades ou pela satisfação psicológica intangível, apesar disso, não são feitos muitos investimentos em estudos de como inovar significados. O autor acredita que haja um campo inexplorado de como o design pode atuar na fase inicial e fluida de uma indústria, quando surge uma

tecnologia inovadora. Dove et al. (2017) afirmam que a tecnologia geralmente entra no mercado como um avanço técnico e sem muita preocupação com o design. À medida que a tecnologia amadurece, os designers trabalham para inventar novas formas de aplicação.

Norman e Verganti (2014) escreveram um artigo juntos, dada a congruência de seus estudos individuais. Ambos concordaram com a importância do design centrado no humano para a inovação incremental e sua fraqueza na inovação radical, a qual seria motivada pela evolução da tecnologia. Para os autores, o design centrado no humano tende a assumir que a inovação deve surgir da observação dos usuários. As necessidades do usuário são analisadas e procuram-se tecnologias ou meios que possam satisfazê-los. Inicia-se, então, um processo iterativo de prototipagem e testes até que se alcance um produto utilizável e compreensível. A questão é que uma série de inovações radicais de sucesso que não foram originadas dessa maneira. Todas as que foram identificadas pelos autores, foram alavancadas pelas novas possibilidades da tecnologia, sem bases em pesquisas de usuários formais. Acreditamos que essa constatação apenas retrata a realidade do mercado, não o cenário ideal. O estudo de design centrado no humano pode amadurecer, evoluir e originar inovações radicais.

Segundo Verganti et al. (2020), as decisões ocupam o ponto central em um processo de inovação e sempre foram tomadas pelos seres humanos, mas agora elas podem ser tomadas pelos algoritmos de AI (inteligência artificial), os quais processam uma grande quantidade de dados em alta velocidade. Ainda, de acordo com os autores, a AI reforça os princípios do *Design Thinking*: ser centrado nas pessoas, abduutivo e iterativo. O design centrado nas pessoas pressupõe entender um problema da perspectiva do usuário e prever o que seria significativo para ela, em vez da inovação ser impulsionada pelos avanços da tecnologia e suas possibilidades. Para os autores, a AI até ultrapassa a abordagem centrada no humano, pois sai de um conceito de perfil de usuário relativo a um segmento de pessoas para alcançar a personalização para cada usuário, relativo a um indivíduo. No design abduutivo trabalha-se com hipóteses sobre como coisas podem ser em vez de seguir um raciocínio dedutivo - como as coisas são - ou raciocínio indutivo - como provavelmente as coisas são. Com o design iterativo, equipe e os usuários são envolvidos em iterações nas quais as soluções são testadas e refinadas, até que um resultado satisfatório seja alcançado. Com a AI, a atualização é constante devido às iterações de aprendizado em todo o ciclo de vida do produto, o chamado *machine learning* - aprendizado de máquina -, e pelo aprendizado ser contínuo, a solução experimentada por um usuário está em constante evolução.

Testemunhamos o surgimento de empresas baseadas em um único produto totalmente digital e inovador com AI em seu ponto central, como a Netflix. Nesse contexto, Verganti et al. (2020) assumem que a AI altera a prática do design. Algumas decisões de projeto tradicionalmente executadas pelos designers, agora são automatizadas em ciclos de aprendizado. Uma solução específica com a qual um usuário individual interage é projetada por um mecanismo de AI com ciclos de solução de problemas. Dados da interação são coletados em tempo real e processados imediatamente pela AI incorporada ao produto. Um algoritmo pode gerar de forma autônoma uma nova solução específica para cada usuário, sem nenhum esforço humano envolvido. À medida que novos dados são coletados continuamente e o mecanismo de AI incorpora recursos de aprendizado, os ciclos de solução de problemas melhoram suas previsões sobre as necessidades e comportamentos do usuário e projetam melhores soluções. O trabalho

dos seres humanos é conceber as bases para uma nova oferta e projetar os ciclos de solução de problemas.

Verganti et al. (2020) identificam que a Netflix transformou o cenário da mídia aproveitando-se do poder do *Big Data* e da AI. Quase todos os aspectos do negócio, desde a personalização da experiência do usuário até a orientação para suas próximas produções são conduzidos pelos algoritmos. Os autores comentam que a Netflix introduziu a AI aproximadamente em 2010, em seu mecanismo de recomendação. Em 2014, começou a investir na compreensão do comportamento do usuário e desenvolver experiências de *streaming* personalizadas. As telas atuais são “projetadas em tempo real” por uma máquina. Limites e parâmetros são especificados por humanos, mas as decisões sobre quais filmes exibir, como exibi-los, com quais imagens representá-los e outras decisões de design são tomadas por algoritmos.

Segundo Verganti et al. (2020), a utilização de AI em produtos digitais promove muitas mudanças no processo de design. O humano não projeta mais a solução final com todos os detalhes, mas os parâmetros para a AI projetar a interface personalizada. Os designers não foram educados para projetar dessa maneira. Agora, eles precisam imaginar como o sistema irá funcionar em escala. Além de que, as etapas do processo tradicional de design - projeto, entrega e uso -, agora ocorrem simultaneamente. Yang (2017) supõe que os designers estão atrasados em projetos dessa tecnologia não tão nova, pois ainda não possuem prática, conhecimento e ferramentas adequadas aos projetos com ML. Cramer e Thom (2017) ressaltam que as decisões de design afetam os resultados do aprendizado de máquina e a interação humano-computador. Sendo assim, é muito importante que os designers se envolvam nos projetos de ML visando melhorar a experiência dos usuários. Para projetarmos melhores experiências com a AI, precisamos entender os novos padrões e reformular o processo de design, adequado às especificidades do desenvolvimento de produtos com AI. Feito isso, os UX designers precisam de capacitação educacional e profissional para adequarem as suas competências. Até porque, como dependem mais do conhecimento multidisciplinar, devem saber dialogar com os cientistas de dados, para projetar as interfaces.

Dove et al. (2017) também alegam que é difícil para os designers trabalharem com ML, pois eles têm ferramentas de prototipagem mas são inadequadas para projetos de ML, já que não têm nada que os ajude a entender rapidamente o impacto no UX de respostas falso-negativas e falso-positivas de um serviço de ML. Os autores dizem até mesmo, que é possível que os designers de UX não tenham uma compreensão clara do que é ML e de sua capacidade. Os autores observam que o ML representa uma oportunidade pouco explorada e que, para os designers de UX, o ML oferece um potencial ainda desconhecido em relação ao design. Verganti et al. (2020) concluem que da mesma maneira que a AI impulsiona uma prática aprimorada de design, o design também pode impulsionar uma implementação de AI mais eficaz e centrada no ser humano.

O emprego de ML parece ter sido impulsionado principalmente pela disponibilidade de dados e avanços tecnológicos, em vez de surgir a partir de uma necessidade do usuário e seguir uma visão centrada no humano. O papel do UX designer e investimentos em estudos de usuários são fundamentais para projetar boas soluções. O PAIR (*People + AI Research*) – guia de inteligência artificial da Google – indica que se deve encontrar a interseção das necessidades do usuário e dos pontos fortes da AI, para assim, resolver problemas reais de maneira que a AI agregue um valor único. “Até a me-

lhor AI falhará se não fornecer um valor exclusivo aos usuários.” (GOOGLE PAIR, 2019, tradução nossa)

Endsley e Jones (2004) informam que tradicionalmente, os sistemas são projetados e desenvolvidos para executar sua função a partir de uma perspectiva centrada na tecnologia. As autoras relatam que os projetistas técnicos desconsideram o processamento humano de informações, o que gera uma sobrecarga no processo mental dos usuários dos sistemas. Muitos dos erros atribuídos ao humano são provenientes da tecnologia projetada de maneira inadequada. As autoras defendem que a maneira de projetar sistemas mais eficazes é aplicar o design centrado no usuário, que desafia os projetistas a moldar a interface em torno dos recursos e necessidades dos usuários, para obter o funcionamento ideal de todo o sistema humano-máquina. Dessa maneira, os erros são minimizados e a produtividade melhorada, além da aceitação e satisfação do usuário.

A questão que confronta a tecnologia com o humano é a mudança do foco do “que os produtos podem fazer” para “o que as pessoas precisam que eles façam e como”. Os avanços tecnológicos e as inovações precisam acompanhar as necessidades humanas. Jordan (2000) já apontava que os fatores humanos eram cada vez mais considerados em relação ao design de produto, visto que o mercado aumentara o número de especialistas em prol do atendimento das necessidades de quem usariam os produtos produzidos. Segundo o autor, quinze ou vinte anos antes, poucas indústrias empregavam especialistas em fatores humanos [ergonomia]. Ainda assim, o autor complementa que, “(...) espera-se que profissionais como designers industriais e designers de software tenham uma consciência dos problemas dos fatores humanos e os coloquem no centro do processo de design” (JORDAN, 2000, p.1, tradução nossa)

Independente da tecnologia, qualquer interface digital precisa ser centrada no humano para funcionar de acordo com o modelo mental de seus usuários e garantir uma boa experiência para eles. A interação do usuário com sistemas de ML não foge a essa regra. Por se tratar de um campo em recente expansão, traz novos desafios aos designers e cabe ainda bastante pesquisa, amadurecimento e evoluções. O PAIR também indica que o foco esteja nas pessoas e não na tecnologia. “Conversar com as pessoas, examinar dados e observar comportamentos pode mudar seu pensamento da *technology-first* para *people-first*.” (GOOGLE PAIR, 2019, tradução nossa).

## 7 A EXPERIÊNCIA DO USUÁRIO COM SISTEMAS DE INTELIGÊNCIA ARTIFICIAL

A ampliação da prática de capturar, armazenar e alimentar sistemas de aprendizado de máquina com dados comportamentais vem transformando a experiência do usuário. Springer et al. (2017) ressaltam que algoritmos ocultos regem cada vez mais nossas vidas, tomando decisões por nós todos os dias. Na realidade, esses sistemas apenas influenciam em nossas decisões, inferindo as melhores opções para ajudar na nossa escolha. O grau de influência está diretamente relacionado ao grau de confiança que o usuário deposita no sistema. O Google Maps ou o Waze mostram as rotas mais rápidas para nossos destinos; o Facebook e o Instagram selecionam que conteúdo dos nossos amigos devemos ver; e a Netflix e o Youtube recomendam que filmes/ séries/ vídeos devemos assistir. O Deezer e o Spotify sugerem que música devemos ouvir. Segundo Springer et al. (2017), essas decisões tomadas a nosso favor influenciam diretamente nosso comportamento.

Nye (2006) ressalta a importância da tecnologia na vida dos humanos, tornando-se indispensável. Somos íntimos dos dispositivos e máquinas pois estão presentes em nossa vida desde nosso nascimento, mas raramente refletimos sobre nossa relação com eles. O autor levanta alguns questionamentos importantes sobre como o nosso relacionamento com as máquinas muda; se as máquinas nos moldam ou se nós as moldamos; se tornam o mundo mais ou menos democrático, mais seguro ou mais perigoso; dentre outros.

Os sistemas de recomendação que utilizam ML já estão amplamente difundidos pela web, por exemplo em *e-commerce* e *streaming* de conteúdo áudio e/ou visual, assim como em aplicativos variados que exploram comportamentos e dados contextuais dos usuários. A funcionalidade de recomendação busca oferecer ao usuário um caminho direto ao conteúdo adequado ao perfil dele. O algoritmo de ML se propõe a conhecer o usuário, aprender com ele e fazer previsões cada vez mais certas do tipo de conteúdo que ele escolheria, baseado em análise de dados de comportamento e comparações. Além de recomendações, os algoritmos podem filtrar mensagens indesejadas, fazer previsões – tempo de viagem, por exemplo – e registrar comportamento - como caminhar ou dormir. Na teoria, esse funcionamento parece o ideal quando se trata de design centrado no humano, economizando esforço cognitivo e tempo do usuário na tomada de decisões, apresentando uma navegação personalizada para cada indivíduo.

Bodegraven (2017) faz uma relação com o que Eli Pariser descreveu como “a bolha do filtro” em 2011, sobre como a web personalizada influenciava a leitura e o pensamento das pessoas, com os sistemas preditivos. Ele acredita que mesmo risco se aplica quando os dispositivos antecipam nossas necessidades e agem de acordo com elas. Forma-se uma bolha de experiência na qual o usuário fica preso em um ciclo de interação com o conteúdo. “Quando tudo é previsto e antecipado sem a oportunidade de mudar esse padrão, viola o conceito de livre arbítrio.” (BODEGRAVEN, 2017, p. 437, tradução nossa). O PAIR (2019) afirma que existem muitas situações nas quais as pessoas preferem que a AI apenas amplie suas habilidades em vez de automatizar completamente uma tarefa. Sendo assim, evitar a formação de bolha é um fator muito importante para o sucesso da recomendação, pois o usuário precisa estar no controle do sistema. A recomendação deve funcionar a favor do usuário, facilitando a sua escolha, mas a decisão final deve ser do usuário.

Bodegraven (2017) conclui que os princípios de design ainda utilizados de Rams, Nielsen (1998), Norman (2013) e Schneiderman (2009) são insuficientes para automação, pois desconsideram os princípios de transparência, controle, *loops* e privacidade, mas reforça que o UX Design é fundamental para oferecer ao usuário uma experiência inédita e preditiva com a tecnologia. Quando esses princípios de design foram estabelecidos, não existiam tantas interfaces com AI/ML presentes em nosso cotidiano. Naturalmente, princípios típicos do contexto da AI não foram considerados, mas agora é preciso voltar a atenção para o impacto que a AI traz para a interação humano-computador.

Para Girardin e Lathia (2017), os sistemas de recomendações, previsões ou contextualização estão definindo como humanos e máquinas interagem. Allen (2017) afirma que os sistemas de ML/AI são contextos muito diferentes dos que os do design tradicional para dispositivos móveis, web, serviços e produtos. Os sistemas de ML/AI geralmente não são visuais e se concentram em comportamentos complexos e interações

estendidas com várias pessoas e sistemas digitais, equilibrando objetivos com uma abordagem colaborativa que não se concentra apenas na conclusão da tarefa. Como os sistemas de ML/AI estão constantemente aprendendo, se adaptando e renegociando com outros sistemas e seres autônomos em evolução, as restrições e os objetivos do projeto são diferentes dos UX convencionais.

Allen (2017) argumenta que o conceito de Design Centrado no Humano perde força e muda o foco para o sistema e seus resultados, no contexto em que os participantes digitais têm seus próprios objetivos, necessidades, intenções, ética, humor e métodos, que gera um sistema orgânico, imprevisível e em evolução. Ele propõe que, para avançar no campo do ML/AI, precisamos repensar o papel do Design, romper com as convenções e inventar novos padrões.

Nós acreditamos que independente da tecnologia, qualquer interface digital precisa ser centrada no humano para funcionar de acordo com o modelo mental de seus usuários e garantir uma boa experiência para eles. A interação do usuário com sistemas de ML não foge a essa regra. Por se tratar de um campo em recente expansão, traz novos desafios aos designers e cabe ainda bastante pesquisa, amadurecimento e evoluções.

Holzinger (2018) explica a abordagem que pode ajudar nessa questão de unir análise de dados e necessidades dos usuários, a HCI-KDD (*Human-Computer Interaction – Knowledge Discovery/Data Mining*): embora o foco central esteja no desenvolvimento do algoritmo, o sucesso do ML exige um esforço conjunto multidisciplinar. Um projeto de ML precisa combinar a interação humano-computador (HCI) - que lida com a compreensão da inteligência, enraizada na ciência cognitiva, relacionada à inteligência humana; e o conhecimento na descoberta e mineração de dados (KDD) - enraizada na ciência da computação, relacionada à inteligência artificial.

Para Winograd (1997), projetar uma interface implica em focar na pessoa, na máquina e no espaço que fica entre elas. Devemos considerar também o “espaço interespacial” que é habitado por várias pessoas, estações de trabalho, servidores e outros dispositivos em uma complexa rede de interações. Através de sistemas e aplicativos, os usuários percebem, agem e respondem a experiências. Winograd (1997) aponta que o sucesso do design de interação depende da mudança de foco da máquina para a vida das pessoas que a utilizam. Nesta dimensão humana, os fatores relevantes tornam-se difíceis de identificar e quantificar. Por isso, é importante investir no estudo da experiência do usuário com a AI, para traçar os limites das ações realizadas pela máquina, que atendam as necessidades das pessoas. Os sistemas devem ser projetados para servir aos seus usuários.

Embora os sistemas de ML pareçam autônomos ao tomar decisões, eles são feitos para humanos e por humanos. São decisões humanas que direcionam o processamento e mineração de dados, a seleção de metas de otimização e o diálogo projetado com os usuários finais com seus mecanismos de feedback implícitos e explícitos. Dessa maneira, são totalmente influenciados por humanos, desde as decisões de projeto até a interação. Segundo Cramer e Thom (2017), as decisões humanas afetam os resultados dos sistemas de ML em praticamente todas as etapas do processo. Eles apontam ainda que o ecossistema que envolve qualquer sistema de aprendizado de máquina é um assunto completamente humano, seja conscientemente projetado ou não.


É justamente devido ao fato de o direcionamento do ML ser dado por humanos, que surgem os sistemas que refletem preconceitos humanos e estereótipos em

sua tomada de decisão. Nesses casos, novos direcionamentos precisam ser definidos e testados, mas o que garante a imparcialidade? Cramer e Thom (2017) acreditam que é uma oportunidade para designers e pesquisadores contribuírem envolvendo-se no processo de curadoria e rotulagem, pois para eles, as ferramentas de modelagem e treinamento das máquinas são projetadas com foco no processamento de grande volume de dados, não nos valores da experiência humana.

Cramer e Thom (2017) ainda identificam o desafio de se encontrar as métricas relevantes para a satisfação do usuário com os novos modelos de interação, para garantir que esses sistemas reflitam o comportamento do usuário de maneira significativa e, por sua vez, forneçam um feedback do projeto para melhorar o sistema. Esse feedback pode ser implícito, como medidas comportamentais, cliques, escutas, visualizações; ou explícito, como estrelas e ícone de polegares para cima / para baixo. Os projetistas precisam decidir ainda como refletir cada feedback e a combinação deles no sistema.

Girardin e Lathia (2017) descrevem um ciclo de feedback para os sistemas de ML (Figura 1) como um mecanismo iterativo para personalizar, otimizar, melhorar ou automatizar serviços que usam uma fonte de dados subjacente. Segundo eles, os dados comportamentais inseridos no sistema são tratados estatisticamente pelos algoritmos para gerar conhecimento, o qual enriquece a experiência do usuário por meio de uma interface. Por sua vez, as interações durante essa experiência criam novos dados comportamentais que podem ser usados para treinar novamente o algoritmo de aprendizagem.

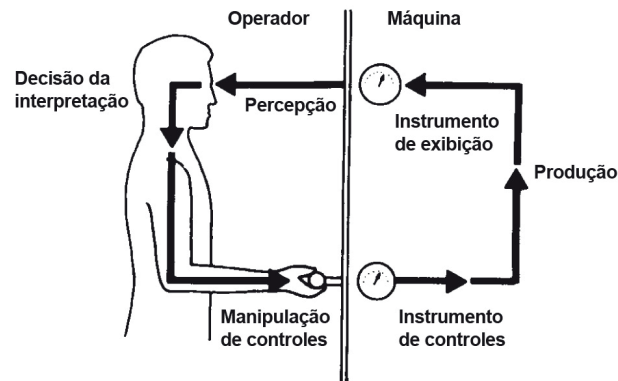
Figura 1 – Ciclo de feedback



Fonte: GIRALDIN E LATHIA (2017, p. 376, tradução dos autores)

Kroemer e Grandjean (2009) descrevem um ciclo fechado para o sistema humano-máquina no qual o humano e a máquina estabelecem uma relação recíproca, mas é o humano que ocupa a posição chave, pois ele é quem toma as decisões (Figura2). A tela provê as informações; o humano percebe e deve ser capaz de entender as informações. Baseado em sua interpretação e conhecimento, o humano toma decisões. Em seguida, o humano comunica sua decisão à máquina através de controles e a máquina processa de acordo como foi programada. O ciclo se fecha quando a máquina apresenta o retorno na tela. Segundo os autores, a máquina é muito veloz e precisa, já o humano é mais flexível e adaptável. Humano e máquina juntos podem formar um sistema muito produtivo, desde que suas qualidades sejam bem empregadas.

Figura 2 – O sistema humano-máquina



Fonte: KROEMER E GRANDJEAN (2009, p.148, tradução dos autores)

Martelaro e Ju (2017) comentam que além das técnicas qualitativas para avaliar a experiência do usuário, como inquirição contextual, enquetes e testes de usabilidade, à medida que os produtos se tornam mais habilitados computacionalmente, somos capazes de gerar e coletar grandes quantidades de dados quantitativos de interação sobre como uma pessoa usa um produto. Os autores apontam que esses dados podem, combinados com sistemas de ML, ser usados para atualizar constantemente o comportamento de um produto, para atender melhor às necessidades dos usuários. Eles ainda explicam que o sistema geralmente coleta apenas dados sobre a interação do usuário com a sua interface, o que pode limitar a capacidade de sugestão de um mecanismo de recomendação, pois não considera contextos, por exemplo. Bodegraven (2017) alerta que para que os sistemas preditivos funcionem bem, é necessário que os dados dos usuários sejam capazes de antecipar necessidades e agir de acordo com elas. Entendemos que é importante buscar e atender as necessidades reais dos usuários, através de uma combinação de métodos e técnicas mais adequadas a cada tipo de projeto.

Assim, quais métodos e técnicas são mais adequados às soluções de UX para interfaces de ML? Para Wright e McCarthy (2008), à medida que novas tecnologias impulsionam mudanças na interação com produtos, surgem oportunidades de novos métodos para se entender as pessoas. O PAIR (2019) indica mapear o fluxo de trabalho dos usuários, assim como fazer pesquisas com usuários e testes com protótipos para avaliar as interfaces de AI.

Acreditamos que haja grupos de usuários diferentes, com diferentes necessidades. Nesse caso, os sistemas de ML deveriam se comportar diferente? Com o ML, podemos gerar métodos para permitir que as máquinas identifiquem as necessidades dos usuários? Em seus estudos, Setlur e Tory (2017) observaram que as pessoas apresentavam variedade de preferências em relação ao comportamento pragmático e diferentes níveis de tolerância ao erro de interpretação. Identificaram que algumas pessoas preferiram ter total controle sobre o comportamento do sistema, mesmo que exigisse mais esforço com instruções de entrada, enquanto outras preferiram uma troca conversacional mais rápida, mesmo que isso gerasse mais correções durante a interação com o sistema. Os autores concluíram ser impossível prever as preferências de um usuário *a priori*, mas que o ideal seria que um sistema pragmático pudesse aprendê-las com base em comandos de reparo anteriores. Além disso, permitir a execução rápida e



fácil de comandos de reparo poderia reduzir os erros de interpretação.

Além disso, Bodegraven (2017) faz um alerta em relação à privacidade de dados. Segundo o autor, os usuários tendem a pensar que “não têm nada a esconder”, e as empresas estão cada vez mais compartilhando dados dos usuários sem que eles saibam e tenham noção das consequências. A automação solicitará muito mais dados a seus usuários para estimar corretamente as necessidades. O PAIR (2019) sugere que o sistema explique aos usuários a origem dos dados e como são utilizados pelo sistema de AI para não prejudicar a confiança, pois os usuários podem se surpreender com suas próprias informações quando as veem em um novo contexto, geralmente quando veem seus dados usados de uma maneira que parece não ser privada ou quando veem dados aos quais não sabiam que o sistema tinha acesso.

O assunto da privacidade de dados torna-se cada vez mais relevante, tanto que é uma preocupação mundial o respeito ao armazenamento e utilização dos dados informados e gerados pelos usuários. No Brasil, temos a LGPD (Lei Geral de Proteção de Dados Pessoais), sancionada em agosto de 2018. Recursos como essa lei são necessários pois as pessoas não têm consciência da quantidade de dados que são possíveis de gerar e de como seus dados podem ser utilizados por instituições de diversos setores. A ideia é que as pessoas tenham ciência e opção de escolha de como seus dados podem ser utilizados para cada finalidade apresentada a elas.

Holzinger (2018) comenta que apesar de o ML superarem o desempenho humano em tarefas específicas, ele possui algumas desvantagens: além da necessidade de grande volume de dados de alto poder computacional e esforço de engenharia, essas abordagens estão se tornando cada vez mais opacas. Ele prevê a necessidade de procedimentos adaptativos ao contexto, ou seja, sistemas que construam modelos explicativos contextuais para classes de fenômenos do mundo real. O autor completa ainda que esse é o objetivo da AI explicável – XAI ou *Explainable AI* em inglês.

Há muitas questões envolvendo a necessidade de os sistemas de ML explicarem seu racional na tomada de decisão para o usuário final. Para Cramer e Thom (2017), se a suposição for de que essas explicações possam ser úteis para o usuário, os recursos de design que afetam o controle e o entendimento devem ser descobertos e explorados. Springer et al. (2017) demonstram em seus estudos que os usuários confiam demais nos algoritmos inteligentes. Bodegraven (2017) ainda alerta que mecanismos antecipatórios privam os usuários de tomada de decisões para reduzir a quantidade de opções para sua escolha. Se por um lado tem a vantagem de reduzir as decisões cotidianas das pessoas, por outro, cria uma bolha de filtro em torno dele mesmo. Bodegraven (2017) afirma que são necessários mais transparência e controle para os usuários conhecerem as decisões básicas e interpretação feitas pelo sistema preditivo. O autor acredita que a implementação de *loops de feedback* pode oferecer aos usuários a oportunidade de se expressarem durante a interação. O PAIR (2019) informa que “explicabilidade” e confiança estão inerentemente vinculadas, embora alerte para o fato de nem sempre ser possível um sistema de AI exibir um alto grau de auto explicação. Helziger (2018) ainda aponta que os modelos com melhor desempenho são os menos transparentes. O PAIR (2019) sugere que o momento perfeito para mostrar explicações seja em resposta à ação do usuário. A transparência dos algoritmos de AI/ML faz-se necessária, principalmente, quando uma recomendação guia uma decisão importante do usuário, que envolve alto risco (de vida, financeiro, por exemplo). Em muitos casos, esse usuário precisa entender a lógica por traz da recomendação, para validar a deci-

sões da máquina e tomar a sua decisão final.

Helziger (2018) enfatiza que abordagens computacionais podem encontrar padrões em espaços arbitrariamente de alta dimensão impossível para qualquer humano. Conseqüentemente, seria necessário o aumento da inteligência humana com inteligência artificial, mas em alguns casos, apenas especialistas humanos são capazes de entender o contexto. Ele conclui que são necessárias soluções para tornar o racional do algoritmo perceptível e manipulável para os humanos. Embora métodos com melhor desempenho sejam os menos transparentes, as tendências atuais de privacidade tornam obrigatórias as soluções transparentes.

Entendemos que para alguns sistemas de ML, geralmente os relacionados a entretenimento como jogos e consumo de mídia, não seja tão importante o racional do algoritmo, mas que para tomadas de decisão mais arriscada, como sistemas médicos e financeiros, os usuários precisem validar o racional do algoritmo para confiar nas previsões. Samek et al. (2017) exemplificam essa questão com carros autônomos, como uma única previsão incorreta pode ser muito onerosa, então a confiança do modelo nos recursos certos deve ser garantida. Para eles, o uso de modelos de AI interpretáveis e explicáveis por humanos é um pré-requisito para fornecer essa garantia.

Além dos sistemas de ML tradicionais que ganham cada vez mais espaço no mercado, surge o iML - aprendizado de máquina interativo – para permitir que os usuários criem e personalizem os sistemas. O usuário tem uma atuação mais ativa e de controle do sistema, enquanto no ML convencional, ele é mais passivo, suas ações servem como input para a máquina aprender com ele, processar as informações e realizar as previsões. Para Bernardo et al. (2017), O iML “democratiza” o aprendizado de máquina, pois permitem o acesso aos benefícios dos algoritmos de aprendizado a mais pessoas.

Helziger (2018) entende que o fato de seres humanos conseguirem aprender e extrair conhecimento de poucos dados ou dados incompletos, seja um forte motivador para o iML, ou seja, usar a experiência, o conhecimento e até a intuição humana para ajudar a resolver problemas que, de outra forma, permaneceriam intratáveis em termos de computação.

A AI traz os dados e algoritmos para o centro do processo de inovação. O desenvolvimento das interfaces de ML ainda está muito focado na capacidade tecnológica da ferramenta, mas para garantir uma boa experiência do usuário, é necessário focar nas necessidades das pessoas. Precisamos identificar os desafios de projeto e saber como resolvê-los. A AI muda profundamente a prática do design e a maneira dos usuários interagirem com as interfaces digitais. O principal é entender como é para as pessoas interagirem com interfaces de ML / AI e quais necessidades são atendidas.

## 8 CONCLUSÃO

Nos últimos anos, pudemos acompanhar um grande crescimento do volume de conteúdo que temos disponível para consumo, impulsionado por diversos fatores. Podemos apontar a tecnologia como um grande fator, pois ela nos proporciona um ambiente digital que amplia a capacidade de armazenamento e elimina distâncias físicas em grande velocidade. Se por um lado, a tecnologia impulsiona o crescimento do volume de conteúdo, por outro, ela cria meios de analisar esses dados armazenados e filtrar conteúdo para as pessoas.

A área de negócios identificou um grande potencial estratégico e já armazena

um grande volume de dados em grande variedade e velocidade há algum tempo. As instituições armazenam informações de vários tipos por diversos meios. Os dados são cada vez mais valorizados pelo mercado e buscam-se conhecimentos para orientar as decisões.

Historicamente, a tecnologia impulsiona as inovações. O que percebemos são projetistas técnicos, muitos sem conhecimento de pesquisa, propondo inovações com grande foco nas funções dos produtos lançados. O mercado recebe esses produtos e na dinâmica de “tentativa e erro”, a maioria falha. Alguns poucos encaixam nas necessidades das pessoas, no momento certo, e alcançam o sucesso. Algumas vezes, processos de design são inseridos nos projetos para identificar e resolver problemas que adequem melhor os produtos a seus usuários. Acreditamos que a abordagem centrada no humano possa resultar em um diferencial, se aplicada também desde o início da concepção de um produto inovador, resultando em produtos mais funcionais e satisfatórios para os usuários.

Produtos inovadores baseados em AI estão cada vez mais presentes em nossas rotinas. Os algoritmos de AI se proliferam pelas interfaces digitais, selecionando conteúdo e oferecendo sugestões sob a alegação de facilitar as escolhas das pessoas. A tecnologia traz diversos benefícios para as nossas vidas, mas precisamos ser críticos quando entendemos a dependência que temos dela. O quanto podemos confiar nas previsões das máquinas?

Esta pesquisa limitou-se a uma revisão bibliográfica para explorar os temas que convergiam para o embasamento do estudo relacionado à experiência do usuário com sistemas de Inteligência Artificial. Buscou-se investigar históricos, conceitos e estado da arte, para apoiar a hipótese de que os sistemas baseados em Aprendizado de Máquina são desenvolvidos com foco no que a tecnologia pode entregar e não nas necessidades das pessoas, o que compromete a experiência do usuário. Permitiu-se assim, chegar às seguintes conclusões: 1) UX designers, muitas vezes, parecem não estar envolvidos nas etapas de requisitos dos projetos; 2) UX designers dependem dos conhecimentos dos cientistas de dados e técnicos para tomarem boas decisões; 3) Alguns métodos e técnicas de UX precisam ser adaptados para os projetos de ML.

Além disso, ao longo desta pesquisa, foram identificados muitos desafios do cenário que envolve a experiência do usuário e ML. Esses desafios são recapitulados abaixo:

1. Adequar os princípios de design tradicionais à realidade da Inteligência Artificial.
2. Entender os novos padrões e alterações no processo de design.
3. Capacitar os UX Designers, pois os mesmos possuem pouca experiência na área e dependem mais do conhecimento multidisciplinar.
4. Evitar a formação de bolhas no ciclo de interação com o conteúdo.
5. Tratar a privacidade dos dados.
6. Estabelecer o limite das recomendações da máquina, respeitando o controle do usuário.
7. Tornar as decisões da máquina compreensíveis (transparência) para estabelecer confiança nas previsões.

Todos esses desafios ainda precisam ser trabalhados e investigados em profundidade para que as interfaces digitais sejam mais avançadas e com foco nos fatores humanos ao mesmo tempo. A experiência dos usuários em relação à interação com os algoritmos de AI/ML precisa ser estudada em profundidade. Esse estudo pode ser orientado pelos problemas já citados pelos pesquisadores aqui apresentados, além de realizar novas descobertas. Como complemento, também é necessária investigação do papel do profissional de UX design no processo de desenvolvimento das interfaces baseadas em AI/ML, para entender como a experiência do usuário é considerada e trabalhada. Além disso, verificar se os métodos de design tradicionalmente empregados para avaliar a experiência com sistemas digitais são adequados para o contexto da interação com sistemas baseados em AI/ML.

## REFERÊNCIAS

ALLEN, Philip van. **Reimagining the Goals and Methods of UX for ML/AI**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

BERNARDO, Francisco; ZBYSZYŃSKI, Michael; FIEBRINK, Rebecca; GRIERSON, Mick. **Interactive Machine Learning for End-User Innovation**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

BODEGRAVEN, Joël van. **How Anticipatory Design Will Challenge Our Relationship with Technology**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

BRIGGS, Asa; BURKE, Peter. **Uma História Social da Mídia: de Gutenberg à Internet**. Rio de Janeiro, Zahar: 2006.

CRAMER, Henriette; THOM, Jennifer. **Not-So-Autonomous, Very Human Decisions in Machine Learning: Questions when Designing for ML**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

DOSI, Giovanni. **Technological paradigms and technological trajectories: A suggested interpretation of the determinants and directions of technical change**. Research Policy, 1982, 11 (3): 147–62.

DOVE, Graham; HALSKOV, Kim; FORLIZZI, Jodi; ZIMMERMAN, John. **UX Design Innovation: Challenges for Working with Machine Learning as a Design Material**. Denver, EUA: CHI, 2017.

ENDSLEY, Mica R.; JONES, Debra G. **Designing for Situation Awareness: An Approach to User-Centered Design**. Boca Raton, EUA: CRC Press - Taylor & Francis Group, 2004.  
GIRARDIN, Fabien; LATHIA, Neal. **When User Experience Designers Partner with Data Scientists**. The AAAI 2017 Spring Symposium on Designing the User Experience of Ma-

chine Learning Systems Technical Report SS-17-04

GOOGLE PAIR. **People + AI Guidebook**. 2019 Disponível em: <https://research.google/teams/brain/pair/> Acesso em: 07 de maio de 2020.

HOLZIGER, Andreas. **From Machine Learning to Explainable AI**. Keynote Talk at IEEE DISA 2018 Conference, Kosice, August, 23, 2018

JORDAN, Patrick W., **Designing Pleasurable Products: An Introduction to the New Human Factors**. Londres: Taylor & Francis, 2000.

KALBACH, J. **Design de Navegação Web: Otimizando a Experiência do Usuário**. Porto Alegre, Brasil: Bookman, 2009.

KROEMER, K. H. E.; GRANDJEAN, E.. **Fitting the Task to the Human**. UK: Taylor & Francis, 2009.

MARTELARO, Nikolas; JU, Wendy. **DJ Bot: Needfinding Machines for Improved Music Recommendations**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

MINELLI, Michael; Chambers, Michele; Dhiraj, Ambiga. **Big Data, Big Analytics: Emerging Business Intelligence and Analytic Trends for Today's Businesses**. New Jersey, EUA: John Wiley & Sons, Inc, 2013.

NATH, Keshab; Iswary, Raja. **What Comes after Web 3.0? Web 4.0 and the Future**. International Conference on Computing and Communication Systems (I3CS'15)

NORMAN, Donald. A. **Technology First, Needs Last: The Research-Product Gulf**. Interactions, 2010, p.38-42.

NORMAN, Donald. A.; VERGANTI, Roberto. **Incremental and Radical Innovation: Design Research vs. Technology and Meaning Change**. Design Issues, 2014, 30(1):78-96.  
NYE, David E., **Technology Matters: Questions to Live With**. Londres, Inglaterra: The MIT Press, 2006.

ROUHIAINEN, Lasse. **Artificial Intelligence: 101 Things You Must Know Today About Our Future**.

ROSENFELD, L; MORVILLE, P; ARANGO, J. **Information architecture for the Web and Beyond**. 1. ed. Sebastopol: O'Really, 2015.

SAMEK, Wojciech; WIEGAND, Thomas; MÜLLER, Klaus-Robert. **Explainable Artificial Intelligence: Understanding, Visualizing And Interpreting Deep Learning Models**. JO - ITU Journal: ICT Discoveries - Special Issue 1 - The Impact of Artificial Intelligence (AI) on Communication Networks and Services, 2017.

SAMPAIO, C. **Web 2.0 e Mashups: Reinventando a Internet**. Rio de Janeiro, Editora Brasport: 2007.

SETLUR, Vidya; TORY, Melanie. **Exploring Synergies between Visual Analytical Flow and Language Pragmatics**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

SPRINGER, Aaron; HOLLIS, Victoria; WHITTAKER, Steve. **Dice in the Black Box: User Experiences with an Inscrutable Algorithm**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

TSIHRINTZIS, George A.; SOTIROPOULOS, Dionisios N.; e JAIN Lakhmi C.. **Machine Learning Paradigms**. Suíça: Springer, 2019.

VERGANTI, Roberto. **Radical Design and Technology Epiphanies: A New Focus for Research on Design Management**. J Prod Innov Manag, 2011;28:384–388

VERGANTI, Roberto; VENDRAMINELLI, Luca; IANSITI, Marco. **Innovation and Design in the Age of Artificial Intelligence**. J Prod Innov Manag, 2020;37(3):212–227

WINOGRAD, Terry. **The Design of Interaction. Em Beyond Calculation: The Next Fifty Years of Computing**. Nova York, EUA: Springer, 1997. P.149–161

WRIGHT, Peter; MCCARTHY, John. **Empathy and Experience in HCI. Em Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, CHI '08**, 637–646. EUA, Nova York: ACM, 2008.

WURMAN, Richard Saul. **Information Anxiety 2**. Indianapolis, EUA: Que, 2001.

YANG, Quian. **The Role of Design in Creating Machine-Learning-Enhanced User Experience**. The AAAI 2017 Spring Symposium on Designing the User Experience of Machine Learning Systems Technical Report SS-17-04

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.