

FAPESP 60 Anos: A Ciência no Desenvolvimento Nacional

60 Years of FAPESP:
Advancing Science
for National
Development



Uma homenagem da
Academia de Ciências do Estado de São Paulo
A tribute from the São Paulo State Academy of Sciences



Capítulo 5

Computação: ciência, engenharia e arte

Chapter 5
Computing: science, engineering and art

CONTEXTUALIZAÇÃO
Este capítulo se concentra em alguns dos muitos temas de pesquisa em Computação e como ela influencia e é influenciada por todos os demais domínios do conhecimento. Ele explora a interação entre três eixos essenciais – dados, algoritmos e hardware. A execução de algoritmos gera dados; a análise de dados induz à criação

<https://doi.org/10.4322/978-65-86819-27-4.1000005>
(cc) Exceto onde indicado de outra forma, este é um capítulo publicado em acesso aberto (Open Access) sob a licença [Creative Commons Attribution-NonCommercial](#), que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que sem fins comerciais e que o trabalho original seja corretamente citado.
Except where indicated otherwise, this is an Open Access chapter distributed under the terms of the [Creative Commons Attribution-NonCommercial](#) license which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

de modelos e algoritmos; e dados e algoritmos são usados para criar especificações executáveis de hardware, em um ciclo em constante evolução. Esta evolução está cada vez mais sujeita aos aspectos éticos da Computação – se os artefatos computacionais influenciam todos os aspectos de nossas vidas, precisamos especificar e interagir com tais artefatos de maneira responsável. Ao mesmo tempo que a pesquisa em Computação acelera e permite pesquisas em outras áreas, novas descobertas em outros domínios também contribuem para o avanço da pesquisa e desenvolvimento da Computação. A cada nova descoberta, este círculo virtuoso permite avançar o conhecimento que temos sobre nós mesmos e o mundo que nos cerca. Algoritmos e dados permitem que cientistas conheçam mais sobre todos os seres vivos – biologia, fisiologia, cognição, interações, evolução.

CONTEXT
This chapter focuses on some of the many research topics in Computing¹ and how it influences and is influenced by all other domains of knowledge. It explores the interaction between three central dimensions – data, algorithms and hardware. The execution of algorithms produces data; the analysis of data leads to the creation of models and algorithms; and data and algorithms are used to create executable specifications of hardware, in a constant cycle of evolution. This evolution is increasingly subjected to the ethical dimensions of Computing – if the computational artifacts influence all aspects of our lives, we must define and interact with such artifacts in a responsible way. At the same time that research in Computing accelerates and facilitates research in other areas, new discoveries in other domains also contribute to advances in Computing research and development.
¹ This chapter uses the term “Computing” with a capital “C” to encompass all research, development and innovation in Computer Science and Engineering.



With each new discovery, this virtuous cycle allows a better understanding of ourselves and of the world around us. Algorithms and data enable scientists to learn more about all living beings – biology, physiology, cognition, interactions, evolution. And (though not exclusively) for humans, this also involves studying sociological and psychological aspects and what drives and moves us.

INTRODUCTION – COMPUTING FROM THE MICRO TO THE MACRO, FROM THE SIMPLE TO THE COMPLEX
The title of this chapter was inspired by the classic text “The Art of Computer Programming” (Knuth, 1998), which all computer scientists know. Written in the 1960s, and expanded over several editions, it analyzes a large number of algorithms, formally proving the complexity of their specifications (in terms of execution time and storage space), discussing their implementation and comparing them with “art”. In fact, not only is Computer Science a science; its practice involves art.

E, principalmente para humanos, aspectos sociológicos, psicológicos e, até mesmo, o que nos move e comove.

INTRODUÇÃO – A COMPUTAÇÃO DO MICRO AO MACRO, DO SIMPLES AO COMPLEXO
O título deste capítulo foi inspirado pelo texto clássico “The Art of Computer Programming” (Knuth, 1998), que todo cientista da computação conhece. Escrito nos anos 1960, e ampliado ao longo de várias edições, analisa um grande número de algoritmos, provando formalmente a complexidade da sua especificação (em termos de tempo de execução e espaço de armazenamento), discutindo sua implementação e comparando-os com “arte”. E sim, Computação é muita ciência, e fazê-la exige arte. A pesquisa e desenvolvimento em Computação acarretam avanços científicos, tec-

E sim, Computação é muita ciência, e fazê-la exige arte.

nológicos, socioeconômicos e culturais, influenciando e contribuindo para o avanço do conhecimento em pesquisas que vão desde outros universos (astronomia) ao interior do ser humano (microbiologia), chegando ao centro da terra (vulcanologia, geologia). Permitem reconstituir o passado (arqueologia, paleontologia) e projetar visões de futuro. Envolvem não apenas a especificação de algoritmos e o desenvolvimento de software, mas também a criação, projeto e construção de novos equipamentos e sistemas computacionais para atender às necessidades de captura e processamento de dados e, assim, entender o mundo que nos cerca.

Do micro ao macro, encontramos software embarcado – de telescópios a microscópios, na construção de supercomputadores até telefones celulares e microssores, interligados ou não, isoladamente ou participando de redes mundiais. Onde quer que se olhe, o que quer que se use, sistemas computacionais são criados e desenvolvidos com ciência e arte, baseando-se em dados e algoritmos. E a construção de quaisquer equipamentos exige engenharia, que é planejada e dirigida por dados e algoritmos.

O trabalho conjunto de pesquisadores em Computação e em todos os outros domínios do conhecimento é denominado de “eScience”. O termo abrange tanto pesquisas “dirigidas pelos dados” quanto “dirigidas pelo processamento”. A primeira é aquela em que a coleta e o processamento de grandes volumes de dados permitem descobrir novos fatos. A pesquisa “dirigida pelo processamento” é aquela que demanda grande poder computacional para, por exemplo, simulações executadas em grandes conjuntos de processadores paralelos, chegando a envolver milhões de horas de processamento – como, por exemplo, em estudos de dinâmica dos fluidos. No primeiro tipo, a ênfase são os algoritmos e os dados usados como entrada, sempre em grande volume, para permitir inferências e tomadas de decisão. No segundo tipo, o diferencial é a necessidade de poder computacional, principalmente para simulações. Alguns tipos de situação envolvem tanto pesquisas dirigidas pelos dados quanto pelo

Research and development in Computing involve technological, scientific, socioeconomic and cultural advances, influencing and contributing to the development of knowledge in research that ranges from other universes (astronomy) to the interior of human beings (microbiology), and reaching the center of the earth (vulcanology, geology). They allow us to reconstruct the past (archaeology, paleontology) and project visions of the future. And they involve not only specifying algorithms and developing software but also the creation, design and construction of new computational equipment and systems to meet the demands of data capture and processing and, thus, understand the world around us.

Embedded software is found from the micro to the macro – from telescopes to microscopes, in building supercomputers, cell phones and microsensors, interconnected or not, isolated from or participating in global networks. Wherever we look, whatever we use, computational systems are created and developed with science and art, based in data and algorithms. And the construction of any equipment requires engineering that is planned and guided by data and algorithms.

The joint work of researchers in Computing and any other domain of knowledge is named “eScience”. The term includes both research “driven by data” and “driven by processing”. The former relies on the collection and processing of large volumes of data to enable the discovery of new facts. Research “driven by processing” requires significant computational power, for instance, for simulations performed with large sets of parallel processors, possibly involving millions of processing hours – for instance, in studies of fluid dynamics. In the first type, the emphasis is on algorithms and the data used as input, always in large volumes, to allow inferences and decision making. In the latter, the specificity is the need for computing power, mainly for simulations. Some situations involve both data-driven and processing driven research – for instance, in biodiversity studies (see chapter 3) or climate change (see chapter 2).

From this perspective, “data” are static, that is, cannot be executed, while “algorithms” specify the logic of processing – whether for data analysis or to run models defined, for instance, by mathematical equations. The difference between data and algorithms is becoming increasingly subtle – data processing can generate more data, but can also produce models; and the processing of an algorithm can generate “static” data, but also new algorithms (as in Artificial Intelligence).

If we thus consider that algorithms can extract new correlations, facts and models based on data, and that data processing can generate new algorithms, the difference between data and algorithms, although persisting, becomes increasingly

tenuous. Regardless of these differences, data and algorithms are at the foundation of advances obtained in Computing. How do they interact and what are the challenges faced to develop research in this area? What are the current developments for new types of hardware that integrate this data-algorithms symbiosis? Figure 1 summarizes this scenario. This chapter gives a brief overview of some of these challenges, exemplifying them based on problems in a few specific domains, while also highlighting their human, social and economic impacts, and the ethical dilemmas they might pose.

BIG DATA, SMALL DATA AND THE DATA LIFE CYCLE
To understand the future of Computing, we introduce two concepts – “big data” and the “data life cycle”. The notion of

processamento – por exemplo, em estudos de biodiversidade (como no capítulo 3) ou mudanças climáticas (como no capítulo 2).

Nessa conceitualização, “dados” são estáticos, isto é, não podem ser executados, enquanto “algoritmos” especificam a lógica de algum processamento – quer para análise de dados, quer para executar modelos que são definidos, por exemplo, por equações matemáticas. A diferença entre dados e algoritmos está ficando cada vez mais sutil – o processamento de dados pode gerar mais dados, mas também gerar modelos; e o processamento de algoritmos pode gerar dados “estáticos”, mas também novos algoritmos (como em Inteligência Artificial).

Se pensarmos, agora, que algoritmos podem extrair novas correlações, fatos e modelos a partir dos dados, e que o processamento dos dados pode gerar novos algoritmos, a diferença entre dados e algoritmos fica cada vez mais tênue, embora persista. Independente dessas diferenças, dados e algoritmos estão na base de todos os avanços obtidos em Computação. Como é que eles interagem, e quais os desafios enfrentados para desenvolver pesquisa nessa área? E que direções existem para novos tipos de hardware que comportem esta simbiose entre dados e algoritmos? A Figura 1 ilustra este cenário sinteticamente. Este capítulo dá uma breve visão sobre




Figura 1. Conceitos abordados no capítulo – algoritmos e dados geram novos dados, algoritmos e hardware, em ciclos virtuosos. O hardware é necessário para a execução. Dados e algoritmos gerados podem ser usados para aprimorar dados e algoritmos. E pessoas, isoladamente ou em conjunto, influenciam e interagem com algoritmos, dados e hardware, e por eles são influenciadas. Crédito: Concepção artística: autores. Ícones das pessoas: © Mashot/Istockphoto.com.

Figure 1. Concepts considered in the chapter – algorithms and data generate new data, algorithms and hardware in virtuous cycles. Hardware is necessary for execution. The data and algorithms generated, in turn, can be used to improve data and algorithms. People, separately or together, influence and interact with algorithms, data and hardware, and are influenced by them. Credit: Artistic conception by authors. People icons: © Mashot/Istockphoto.com.

alguns desses desafios, exemplificando-os a partir de problemas em alguns domínios específicos, ressaltando também o seu impacto humano, social e econômico – e os dilemas éticos que podem acarretar.

BIG DATA, SMALL DATA E O CICLO DE VIDA DOS DADOS

Para entender os caminhos futuros da Computação, é necessário introduzir dois conceitos adicionais – “big data” e o que é um “ciclo de vida de dados”. A noção de “big data” (termo associado a grande volume) vem sendo disseminada e adotada pelo grande público como sendo a base necessária para grandes descobertas, com a conhecida referência de que dados são o novo petróleo (*The Economist*, 2017). Para melhor entender esta questão, é preciso separar o “big”, que qualifica o volume dos dados, dos desafios de pesquisa associados ao trabalho com dados.

Um “grande volume de dados” (tradução frequente de “big data”) pode ser definido como um conjunto tão grande que técnicas computacionais padrão não são suficientes para processá-lo. Mas à medida que surgem novos algoritmos e hardware mais poderoso, o “grande volume” de cinco anos atrás deixa de sê-lo. Fato é que vivemos num mundo permeado por dados gerados por todo tipo de dispositivo e por nós mesmos (por exemplo, nas redes sociais). E que, graças a esta grande variedade de dados, algoritmos podem realizar deduções e inferências que seriam impossíveis sem os dados como base. Pode-se dizer, assim, que a Inteligência Artificial adquiriu a relevância que hoje tem porque agora conseguimos gerar, armazenar e processar grandes quantidades de dados, e continuamos a desenvolver novos algoritmos e novos computadores que permitam tal processamento.

É comum também ouvir falar nos “V” associados a “big data” – inicialmente três Vs: *Velocidade, Volume, Variedade* (Laney, 2001). O Volume é a essência da definição, como visto acima. Velocidade significa que, se o volume é grande, há problemas

na velocidade do processamento (exigindo novos algoritmos e hardware para melhor desempenho) e na transmissão (também exigindo algoritmos sofisticados para, por exemplo, compactação ou seleção do que se deve transmitir). Finalmente, Variedade significa heterogeneidade – de tipos, de fontes, de formatos.

Só que a heterogeneidade de dados depende do seu volume. Consideremos, por exemplo, uma foto de um ser vivo, que precisa ter metadados associados detalhando como, quando e onde foi obtida, e seu nome científico. A foto e sua descrição são tipos de dados totalmente diferentes que, para serem processados em conjunto, exigem tratamento especial, ou seja, são representantes de “small data” (em termos de volume e exigências computacionais), onde já temos variedade. Também há heterogeneidade se quisermos combinar conjuntos um pouco maiores e mais variados de dados (por exemplo, os vários tipos de dados necessários para um levantamento sobre violência, como no capítulo 7, ou para estudos em produção de alimentos, como os do capítulo 4). Muitos desses estudos não exigem hardware sofisticado ou algoritmos avançados. No entanto, são caracterizados por uma grande heterogeneidade de dados. Assim, o terceiro “V” do “big data” não é exclusivo de grandes volumes. Já o reverso é verdadeiro – grandes volumes de dados heterogêneos exigem algoritmos sofisticados –, ou seja, a variedade é exacerbada pelo volume. Analogamente, outros “V” comumente associados a “big data” são inerentes a problemas de dados (por exemplo, “Veracidade”, sinônimo de qualidade; “Valor” e a subjetividade da avaliação do valor), que são ampliados à medida que o volume aumenta.

Para entender os conceitos associados a dados, e seu papel em descobertas científicas, é preciso também entender o “ciclo de vida dos dados”, que cobre as etapas de coleta, limpeza (ou curadoria), análise, armazenamento e arquivamento. Como diz o nome, o ciclo de vida indica que dados “nascem” (quando são coletados) e podem eventualmente

“big data” (a term associated with large volumes) is spreading and being adopted by the general public as the necessary basis for significant discoveries, with the well-known citation that data are the new oil (*The Economist*, 2017). To better understand this question, we must separate the “big”, that qualifies the volume of data, from the research challenges involved in working with “data”.

“Big data” can be loosely defined as a set of data so large that standard computational techniques are insufficient to process it. However, with the emergence of new algorithms and more powerful hardware, what was consider a “large volume” five years ago is nowadays no longer so. We live in a world permeated by data generated by all sorts of devices and by ourselves (for example, in social networks). Thanks to this large variety of data, algorithms can perform deductions and inferences that would be impossible without data as a basis. We can affirm that Artificial Intelligence has acquired the relevance it has nowadays because large amounts of data can now be generated, stored and processed, and new algorithms and new computers that allow such processing continue to be developed.

It is also usual to associate “big data” with the so-called “V”s – initially three Vs: Velocity, Volume, Variety (Laney, 2001). Volume is the essence of the definition, as already mentioned. Velocity means that, the bigger the volume, the greater the problems in processing speed (requiring new algorithms and hardware to improve performance) and in data transfer (also demanding sophisticated algorithms, for example, for compaction or selection of what needs to be transmitted). Finally, Variety means heterogeneity – of types, sources, and formats.

However, the heterogeneity of data is independent from its volume. Let us consider, for instance, a photo of a living being, that requires associated metadata detailing how, when and where it was taken, and the scientific name of the photo’s subject. A photo and its description are totally different types of data; to be processed together, they require special treatment. They are representatives of “small data” (in terms of volume and computational requirements), but where we already have variety. Heterogeneity also appears if we intend to combine slightly larger, more variable data sets (for example, the various sorts of data necessary for a study on violence, as in chapter 7, or about food production, as in chapter 4). Many of these studies do not require sophisticated hardware or advanced algorithms. However, they are characterized by highly heterogeneous data. Therefore, the third “V” of “big data” is not exclusive to large volumes. Conversely, the opposite is true – large volumes of heterogeneous data require sophisticated algorithms – that is, variety is exacerbated by vol-

ume. Analogously, other “V”s frequently associated with “big data” are inherent to problems with data per se (for example, “Veracity”, synonymous with quality; or “Value” and the subjectivity of the assessment of value), which are increased as volume also increases.

To understand the concepts associated with data, and their role in scientific discovery, it is also necessary to understand the “data life cycle”, which encompasses the steps of collection (also called capture), cleaning (or curating), analysis, storage and archiving. As the name implies, “life cycle” means that data “are born” (when they are collected) and can eventually “die” (when they are deleted, destroyed or forgotten – for instance, when the physical substrate is destroyed or information about where they are stored is lost). Many computer scientists also consider that data “die” when they are no longer used, although they continue to exist in storage.

Each of these steps has well defined phases, whose treatment varies according to the domain of knowledge, data provenance, the aims for data use and possible users. For example, collection can be manual (observations, questionnaires), automatic (using equipment or sensors), or a mix of both, always focused on some purpose for which data are being collected. Curation tends to be one of the most expensive lifecycle stages, since it must guarantee quality and reliability for future use. It nearly always requires validation by domain experts. Storage and archiving require documentation associated with the data – the so called “metadata” – that describe each data set according to, for instance, collection instruments, curation algorithms, the context in which the data are collected and preprocessed, and even the conditions for use. Metadata are adopted worldwide to index data-sets, facilitating their search and retrieval. Archival work presupposes long-term storage, using special techniques for organization and preservation (for example, according to reproduction protocols that avoid “digital decay” in which storage is corrupted over time and the data become illegible). All life cycle stages directly influence the quality of the results obtained when processing data sets – sophisticated algorithms are useless if the data lack the quality necessary for its intended application. Notably, the notion of quality is always subjective, being associated with their fitness for use.

There is no absolute quality as a property intrinsic to data. This takes us to the next section, which considers algorithms, particularly those connected with Artificial Intelligence, and how the combination data + algorithms is the basis for decision making. Thus, as we will see, data quality is also linked to their relevance for the solution of a problem.

“morrer” (quando são apagados, destruídos ou esquecidos – por exemplo, quando é destruído o meio físico ou perda de informação sobre onde estão armazenados). Muitos cientistas da computação às vezes consideram que dados “morreram” quando não são mais usados, embora existam armazenados.

Cada uma dessas etapas tem passos bem definidos, em que o tratamento varia de acordo com o domínio do conhecimento, a proveniência, os objetivos do uso dos dados e os usuários possíveis. Assim, por exemplo, a coleta pode ser manual (observações, questionários), automática (usando equipamentos ou sensores), ou um misto de ambas, sempre dirigida por alguma necessidade de uso. A curadoria costuma ser uma das etapas mais caras do ciclo de vida, pois visa garantir a qualidade e confiabilidade para futuros usos. Quase sempre exige validação por especialistas de domínio. Armazenamento e arquivamento pressupõem que há documentação associada aos dados – os chamados “metadados” – que descreve cada conjunto de dados conforme, por exemplo, os instrumentos de coleta, os algoritmos de curadoria, o contexto em que os dados foram coletados e pré-processados, e até mesmo condições para seu uso. Metadados são adotados mundialmente para a indexação de conjuntos de dados, facilitando sua busca e recuperação. A palavra “arquivamento” pressupõe armazenamento duradouro, usando técnicas especiais de organização e preservação (por exemplo, segundo protocolos de cópia para evitar o “decaimento digital”, em que o meio de armazenamento é corrompido com o tempo e torna os dados ilegíveis). Todas as etapas do ciclo de vida influenciam diretamente a qualidade dos resultados obtidos ao processar conjuntos de dados – de nada adianta algoritmos sofisticados se os dados não têm a qualidade desejada para o que se deseja. Notar, aqui, que a noção de qualidade é sempre subjetiva, sendo associada à adequação para o uso (*fitness for use*).

Não existe qualidade absoluta de dados. Isto nos leva à próxima seção, que discu-

te algoritmos, em particular ligados à Inteligência Artificial, e como a combinação dados + algoritmos é a base de tomadas de decisão. Nesse sentido, como veremos, a qualidade dos dados também inclui sua relevância para a solução de um problema.

ALGORITMOS

As duas seções anteriores estabeleceram a base para esta seção, abordando o cenário global no qual a Computação se insere, e os dados nos quais vivemos imersos e que cada vez mais provêm informações sobre tudo e todos. Esta seção aborda questões de Inteligência Artificial, que é resultado da conjunção “algoritmos + dados”. Exemplos de algoritmos e dados no nível externo – cidades inteligentes – são seguidos por exemplos ligados à alimentação, educação, saúde e meio ambiente, descendo ao nível biológico interno (Bioinformática), e finalizando a seção com considerações sobre o que está por trás da geração dos dados – os sinais. A ênfase desta seção é em soluções associadas à Inteligência Artificial (IA), mas há uma infinidade de algoritmos e soluções computacionais que não precisam de IA para obter resultados importantes.

Inteligência Artificial e Aprendizado de Máquina

O termo “Inteligência Artificial” foi proposto e definido em 1955 por John McCarthy como “A ciência e engenharia de fazer máquinas inteligentes” (McCarthy et al., 2006). Após um período de estagnação nos anos 1990, aparece agora como base para apoio à decisão e descobertas em vários domínios, impulsionada pela capacidade de produção de “big data”, a evolução no hardware e o desenvolvimento de novos algoritmos que permitem processar esses dados de forma “similar” à inteligência humana.

É uma área de pesquisa dentro da Ciência da Computação, englobando um vasto corpo de conhecimento, que agrega novos temas tão rapidamente que é difícil acompanhá-la por completo. Quando mencionada, provoca diferentes reações, como medo, esperança, desejo, repulsa, curiosidade e indiferença.



ALGORITHMS

The two previous sections set the basis for this section, considering the global context in which Computing takes place, and the data we live immersed in, which increasingly provide information about everything and everyone. This section considers some issues in Artificial Intelligence (AI), which is itself the result of the combination “algorithms + data”. In what follows, examples of algorithms and data at the external level – smart cities – are followed by examples related to food, education, health, the environment, and descending to the internal biological level (Bioinformatics). The section concludes with considerations about what underpins data generation and processing – the signals. The emphasis of this section is on solutions associated with AI, but there is an infinity of algorithms and computational solutions that do not require AI to obtain valuable results.

Artificial Intelligence and Machine Learning

The term “Artificial Intelligence” was proposed and defined in 1955 by John McCarthy as “the science and engineering of making intelligent machines” (McCarthy et al., 2006). Following a period of stagnation in the 1990s, it is currently the basis for decisions and discoveries in various domains, driven by the production of “big data”, transformations in hardware, and the development of new algorithms that allow processing these data in a manner “similar” to that of human intelligence.

AI is a research area within Computer Science that includes a vast body of knowledge, and has integrated new topics so quickly that it is difficult to remain fully up to date with it. When AI is mentioned, different reactions are observed, such as fear, hope, desire, repulsion, curiosity and indifference. One of these topics, “Machine Learning”, erroneously understood by many as synonymous with Artificial Intelligence, is currently its most visible facet.

“Machine Learning” (ML) is a subfield of Artificial Intelligence that studies, proposes and uses algorithms that are able to learn based on data, which in turn represent past experiences in a specific situation or domain. The learning process is based on knowledge from various domains, mainly from computing and statistics. This strong connection with computing and statistics contributed to the formation of a new knowledge domain, Data Science, in which Machine Learning plays a key role. An important event occurs in the first decade of the 21st century, when the first significant results for learning based on the so called deep learning appeared. Deep learning structures are being increasingly adopted in AI, but until that decade they were little used due to their high computational complexity.

Usually, the result of the learning process in ML is the induction or construction of a model that discovers patterns present in the data. Depending on the task for which the model is being built, it can perform different functions, the most common being to assign a class or category to each new example. To illustrate how this occurs, a Machine Learning algorithm can be applied to a set of purchases made using a credit card (called transactions in Computer Science). Each object in this set is made up of information related to the purchase (for instance, day, hour, price, place), and a class previously defined by an expert (fraud or not fraud). On being applied to the data, the algorithm constructs a model that learns “fraud/not fraud” from the data. If it learns well, the model can then be used to classify new transactions. How can it learn well? This depends on the data quality, on the expert’s knowledge, and on the adequacy of the algorithm developed to construct the model. Without these three components (quality, knowledge and adequacy), it is not possible to guarantee the relevance of the learning result.

Due to this capacity to construct models from data, Machine Learning algorithms are being used with increased frequency and scope. Many of these applications would not be imagined by most of us. They include determining the ideal temperature for preparing your espresso, composing music, writing poems, brewing healthier and tastier beer, translating speech and texts from one language to another, defining the news that will be posted on a social networking app, selecting students for university courses and employees for companies. Additional examples include defining the price to sell a house, recommending films, books, music and dishes, designing new fragrances for perfumes, proposing play strategies for various sports, identifying deforestation areas, detecting spam or controlling a vehicle’s shock absorbers.

Algorithms and data for living better – smart cities

The main objective of many products and services that use models produced by Machine Learning algorithms is to improve quality of life, as well as to provide better preservation, recovery and risk reduction for flora and fauna. The consequence are smart, sustainable environments, of which perhaps one of the most well-known examples are the so-called “smart cities” (Rjab & Mellouli, 2019).

But what is a smart city? A document published in 2014 by the International Telecommunications Union (ITU), the United Nations (UN) agency for information and communication technologies (ICT), already mentioned more than a hundred definitions thereof. The definition adopted by ITU is: “A smart sustainable city is an innovative city that uses ICTs and other means

Um destes temas, “Aprendizado de Máquina”, por muitos erroneamente usado como sinônimo da inteligência artificial, é atualmente sua face mais visível.

O “Aprendizado de Máquina” é uma subárea da Inteligência Artificial que estuda, propõe e utiliza algoritmos capazes de aprender a partir de dados, que por sua vez representam experiências passadas em alguma situação ou domínio. Para isso, utiliza conhecimento de várias áreas, principalmente da computação e da estatística. Esta forte relação com a computação e a estatística contribuiu para a formação de uma nova área de conhecimento, a Ciência de Dados, na qual o Aprendizado de Máquina exerce um papel-chave. Um marco importante ocorre na primeira década do século 21, com os primeiros resultados impactantes de aprendizado baseado em estruturas ditas profundas (*Deep Learning*), cada vez mais disseminadas em IA, e até então pouco utilizadas devido à sua alta complexidade computacional.

Em geral, o resultado do processo de aprendizado é a *indução* ou *construção de um modelo*, que descobre padrões presentes nos dados. Dependendo da tarefa para a qual o modelo está sendo construído, ele pode exercer diferentes funções, sendo a mais comum a de atribuir uma classe ou categoria a cada novo exemplo. Para ilustrar como isso ocorre, um algoritmo de Aprendizado de Máquina pode ser aplicado a um conjunto de compras feitas utilizando um cartão de crédito (chamadas de transações em Computação). Cada objeto neste conjunto é formado por informações relacionadas à compra (por exemplo, dia, hora, valor, local), e uma classe previamente definida por um especialista (fraude ou não fraude). Ao ser aplicado aos dados, o algoritmo constrói um modelo que aprende “fraude/não fraude” com os dados. Se tiver aprendido bem, o modelo pode ser usado para classificar novas transações. Como pode aprender bem? Depende da qualidade dos dados, do conhecimento do especialista e da adequação do algoritmo desenvolvido para construir o modelo. Sem esses três componentes (qualidade, conhecimento e

O “Aprendizado de Máquina” é uma subárea da Inteligência Artificial que estuda, propõe e utiliza algoritmos capazes de aprender a partir de dados, que por sua vez representam experiências passadas em alguma situação ou domínio.

adequação), não há nenhuma garantia do valor do resultado do aprendizado.

Por conta dessa capacidade de construir modelos a partir de dados, algoritmos de Aprendizado de Máquina são utilizados com frequência e abrangência cada vez maiores. Muitas das aplicações não passariam pela cabeça da maioria de nós, como definir a melhor temperatura de preparação de seu café expresso, compor músicas, escrever poemas, preparar cervejas mais saudáveis e saborosas, traduzir fala e textos entre idiomas, definir as notícias que serão apresentadas em um aplicativo de redes sociais, selecionar alunos para cursos universitários e funcionários para empresas, definir o valor de uma casa que será posta à venda, recomendar filmes, livros, músicas e pratos, desenvolver novas fragrâncias para perfumes, estratégias de jogo para vários esportes, identificar áreas de desmatamento, detectar spams nos emails recebidos ou controlar o funcionamento dos amortecedores de veículos.

Algoritmos e dados para vivermos melhor – cidades inteligentes

Muitos dos produtos e serviços que utilizam modelos gerados por algoritmos de Aprendizado de Máquina têm como objetivo principal a melhoria da qualidade de vida das pessoas, além da melhor preservação, recuperação e redução de riscos à fauna e à flora, dando origem a ambientes inteligentes e sustentáveis. Provavelmente, o exemplo mais conhecido de tais ambientes é o que se denomina hoje de cidades inteligentes (*smart cities*) (Rjab & Mellouli, 2019).

Mas o que é uma cidade inteligente? Um documento publicado em 2014 pela União Internacional de Telecomunicações (ITU – International Telecommunication Union), agência da Organização das Nações Unidas (ONU) para tecnologias de informação e comunicação (TICs), já mencionava mais de uma centena de definições. A definição adotada pela ITU é a de que “[...] a cidade inteligente e sustentável é uma cidade inovadora que usa TICs e outros meios para melhorar a qualidade de vida, a eficiência da operação de serviços urbanos e a com-

petitividade, garantindo que atenda às necessidades das gerações presentes e futuras com respeito aos aspectos econômicos, sociais, ambientais e culturais” (International Telecommunication Union, 2014, p. 13).

Cidades inteligentes não são necessariamente cidades baseadas em Inteligência Artificial, mas sim cidades que buscam soluções naturalmente inteligentes, provenientes de seres humanos, para prestar um melhor serviço à sua população. Soluções naturalmente inteligentes são aquelas baseadas em evidências, que dão suporte a uma melhor tomada de decisão pelos gestores. Evidências são obtidas de dados, e big data têm um papel importante por disponibilizarem um volume suficiente de evidências. Contribuíram para o desenvolvimento da área de cidades inteligentes três fatos observados por volta de 2008 (Townsend, 2013).

O primeiro fato foi uma virada no perfil populacional, quando a população urbana ultrapassou a população rural (com a previsão de chegar a 80% em 2100). Com isto, crescem também os problemas e a demanda por soluções, que incluem a oferta de melhores serviços públicos. A rápida urbanização provoca esgotamento e deterioração dos recursos de infraestrutura, com congestionamentos de trânsito, maior poluição ambiental, crescimento do subemprego e do desemprego e declínio econômico. A busca por soluções para esses problemas, que resultem em uma melhor qualidade de vida e um desenvolvimento sustentável, está por trás do conceito de cidades inteligentes.

O segundo fato foi que o número de pessoas conectadas à internet por redes sem fio superou o de pessoas conectadas por redes cabeadas, em paralelo ao aumento considerável do uso da telefonia celular. O terceiro acontecimento foi a transformação da internet das pessoas (IoP – *Internet of People*), em que o número de pessoas conectadas à internet superava o de dispositivos, passando à internet das coisas IoT (*Internet of Things*), em que a situação se inverte e mais coisas do que pessoas estão conectadas à internet. Agora caminhamos para a IoE (*Inter-*

to improve quality of life, efficiency of urban operation and services, and competitiveness, while ensuring that it meets the needs of present and future generations with respect to economic, social and environmental aspects” (International Telecommunication Union, 2014, p. 13).

Smart cities are not necessarily based on Artificial Intelligence, but rather are cities that naturally seek intelligent solutions originating with human beings to offer a better service to their populations. Naturally smart solutions are those based on evidence, and that underpin better decision making by leaders. Evidence is obtained through data, and big data play an important role due to making a sufficient volume of evidence available. Three facts observed around 2008 have contributed to the development of smart cities (Townsend, 2013).

The first was a change in population profile, when the world’s urban population surpassed the rural one (and this proportion is expected to reach 80% by 2100). Given this, the problems and demands for solutions have also grown, including the provision of better public services. Rapid urbanization provokes wearing out and deterioration of infrastructure, with traffic congestion, greater environmental pollution, increased subemployment and unemployment, and economic decline. The search for solutions to these problems, which result in better quality of life and sustainable development, is crucial for the idea of smart cities.

The second fact was that the number of people connected to the internet by wireless networks exceeded the number of individuals connected via cable networks, together with the considerable increase in mobile phone use. The third event was the movement from the Internet of People (IoP) – in which the number of people connected to the internet is greater than the number of devices – to the Internet of Things (IoT), where this situation is inverted and more things than people are connected to the internet. Currently, we are heading toward the Internet of Everything (IoE). It is estimated that, by 2025, the proportion between the number of things and the number of people connected to the internet will be close to 10 to 1.

For cities to be able to analyze the data generated, in search of evidence that provides assistance for better decision making, there is a need for computational tools capable of finding patterns and extracting knowledge. The tools that best manage this situation are those based on AI, mainly on models generated by Machine Learning algorithms.

The transformation of a city into a smart city is a medium to long-term process. Various activities are necessary, repeatedly covering the whole data lifecycle, to make sure it works. Data capture and analysis will support analyses for decision making on which activities to undertake for this

transformation. These activities should be monitored using new data collection processes, which should include the perception of the population about the changes underway. With each repetition of the life cycle, new decisions can be made.

As seen in the previous section of this chapter, the data collection stage requires the definition of which data to collect, and how. Countless studies propose indicators to guide data collection for smart cities, seeking to allow the analysis of how smart a city is and provide assistance to define goals and “deliverable” products, as well as of the progress throughout the transformation. To this end, such indicators should be simple and easily measurable, with an elevated level of independence from the context.

Other studies also propose assessment indicators for projects to transform cities into smart cities, in terms of viability, expected impact and risks. Such indicators also need to consider the progress achieved during the transformation and compare that progress with the strategic goals and objectives.

One of the studies about indicators was performed by the United for Smart Sustainable Cities (U4SSC) committee, coordinated by three UN agencies: International Telecommunication Union (ITU), The United Nations Economic Commission for Europe (UNECE), one of the five regional commissions of the social and economic council of the UN, and the UN-Habitat agency dedicated to promoting more socially and environmentally sustainable cities. Researchers from various countries, including Brazil, take part in these committees (International Telecommunication Union, 2014).

The U4SSC report proposes 91 key performance indicators organized into three topics or dimensions: economy, environment, and society and culture. These indicators include, among other aspects: open data availability, drinking water quality, sanitation, research and development expenditure, unemployment rate, air quality, environmental protected areas, school enrolment, life expectancy and pedestrian infrastructure. A platform was developed to assess the level of maturity of cities using these indicators.

This platform, in turn, inspired the development of a national platform for the Chamber of Cities 4.0 in Brazil (Câmara das Cidades 4.0). It was the outcome of an initiative of the Ministry of Science, Technology and Innovation (MCTI in Portuguese) and of the Ministry of Regional Development (MDR in Portuguese), in partnership with The Renato Archer Center for Information Technology (Centro de Tecnologia e Informação Renato Archer) and the National Education and Research Network (RNP - Rede Nacional de Ensino e Pesquisa) (Ministério da Ciência, Tecnologia e Inovações, 2021). The Brazilian platform has 114 indicators and includes

net of Everything). Estima-se que até 2025 a proporção entre o número de coisas e o número de pessoas conectadas à internet estará próxima de 10 para 1.

Para que as cidades possam analisar os dados gerados, buscando evidências que deem suporte a uma melhor tomada de decisão, são necessárias ferramentas computacionais capazes de encontrar padrões e extrair conhecimento. As ferramentas que melhor conseguem fazer isso são aquelas baseadas em Inteligência Artificial, principalmente em modelos gerados por algoritmos de Aprendizado de Máquina.

A transformação de uma cidade em uma cidade inteligente é um processo de médio a longo prazo. Para que funcione, são necessárias várias atividades, cobrindo todo o ciclo de vida dos dados, repetidamente. Coleta e análise de dados irão instrumentar as análises para tomada de decisão sobre atividades a serem realizadas. Estas atividades devem ser monitoradas por meio de novas coletas, que irão incluir a percepção da população sobre as mudanças ocorridas. A cada repetição do ciclo de vida, novas decisões poderão ser tomadas.

Como visto na seção anterior deste capítulo, a etapa de coleta de dados exige a definição de quais dados coletar e como. Há vários estudos propondo indicadores para guiar a coleta de dados para cidades inteligentes, visando permitir a análise de quão inteligente é a cidade e prover subsídios para a definição de metas e produtos “entregáveis”, bem como do progresso ao longo da transformação. Para isso, devem ser simples, facilmente mensuráveis, com um elevado grau de independência do contexto.

Outros estudos propõem também indicadores para avaliar projetos de transformação de cidades em cidades inteligentes, com relação à viabilidade, impacto esperado e riscos, informando o progresso obtido ao longo da transformação e comparando o progresso com as metas e os objetivos estratégicos.

Um dos estudos sobre indicadores foi realizado pelo comitê Unidos para Cidades Inteligentes e Sustentáveis (U4SSC, *United for Smart Sustainable Cities*), coordena-

do por três agências da ONU: ITU, Comissão Econômica das Nações Unidas para a Europa (UNECE, *The United Nations Economic Commission for Europe*), uma das cinco comissões regionais do conselho econômico e social da ONU, e ONU-Habitat: agência da ONU dedicada à promoção de cidades mais sociais e ambientalmente sustentáveis. Participam destes comitês pesquisadores de vários países, inclusive do Brasil (International Telecommunication Union, 2014).

O relatório do comitê propõe 91 indicadores-chave de desempenho, organizados em três temas ou eixos: economia, meio ambiente, sociedade e cultura. Estes indicadores, incluem, dentre outros: disponibilidade de dados abertos, água potável e saneamento, investimento em pesquisa e desenvolvimento, taxa de desemprego, poluição do ar, áreas naturais protegidas, matriculados nas escolas, expectativa de vida e infraestrutura para pedestres. Uma plataforma foi desenvolvida para a avaliação do nível de maturidade de cidades por meio destes indicadores.

Esta plataforma serviu de inspiração para o desenvolvimento no Brasil de uma plataforma nacional pela Câmara das Cidades 4.0, fruto de uma iniciativa do MCTI (Ministério de Ciência, Tecnologia e Inovações) e do MDR (Ministério do Desenvolvimento Regional), em parceria com o Centro de Tecnologia da Informação Renato Archer e a Rede Nacional de Ensino e Pesquisa (Ministério da Ciência, Tecnologia e Inovações, 2021). A plataforma nacional, que possui 114 indicadores, inclui um quarto eixo, que avalia as capacidades institucionais de gestão municipal. Este quarto eixo tem indicadores como planejamento da estrutura urbana e de tecnologia da informação e comunicação, serviços públicos on-line, integração e interoperabilidade de serviços e digitalização das bases de dados.

Saúde e agropecuária – dados, algoritmos e dispositivos computacionais

Saúde e agropecuária estão intimamente ligadas, sendo exemplos de áreas de apli-

cação em que algoritmos, dados e novos dispositivos estão trazendo avanços importantes. A agricultura é uma atividade estratégica em todo o mundo, que cada vez mais exige decisões confiáveis, customizadas para os produtos animais ou vegetais, realizadas tanto em curto como em médio e longo prazos e desenvolvidas para escalas temporais e espaciais distintas (local, regional, nacional e mesmo global). Nesse contexto, o uso de algoritmos de IA vem se mostrando eficaz em diferentes tarefas, por exemplo, predição de rendimento de culturas ou detecção automática de pragas. Algoritmos e dados precisam ser específicos para cada solução.

Em paralelo, o desenvolvimento de novos sensores vem tornando a coleta de dados mais precisa e customizada a cada local. Isto está diretamente ligado ao conceito de agricultura de precisão, que utiliza sensores que podem estar em satélites ou embarcados em equipamentos rurais, até redes de sensores sem fio, para coleta e monitoramento. Longe de se limitar a espécies vegetais, o uso de sensores e algoritmos também está crescendo em relação a animais (por exemplo, para aumentar o seu conforto, detectar doenças, monitorar ingestão de alimentos e até mesmo planejar o abate). Sensores, dados e algoritmos se estendem à piscicultura, hidroponia e outras atividades em agropecuária.

Se a Computação é essencial para o ciclo de vida da produção de alimentos, também se tornou fundamental para o ciclo de vida humano. O processo saúde-doença é resultante da integração sistêmica entre aspectos biológicos, genéticos, sociais e ambientais, reunindo desafios transdisciplinares cada vez mais complexos e interconectados. Mais do que a consequência de um agente externo específico, hoje compreendemos que as doenças estão intrinsecamente conectadas com a maneira como somos e vivemos, enquanto seres sociais e biológicos. O prestador de saúde e o paciente podem se beneficiar de soluções computacionais, muitas das quais envolvendo Inteligência Artificial, tanto pelo aumento da acurácia dos diagnósticos

como pela predição de agravos à saúde e implantação de estratégias que reduzam a carga de trabalho dos profissionais e os custos envolvidos.

Um exemplo é o enfrentamento da mortalidade materna e de outras questões associadas à saúde da mulher, em que a grande maioria dos óbitos é evitável e decorre de demoras no processo de oferta de um cuidado adequado. Dados e algoritmos cada vez mais contribuem para facilitar a adoção de recomendações de diretrizes e reforçar a adesão às práticas clínicas. Com efeito, ferramentas de apoio à decisão clínica podem combinar as informações de saúde de um indivíduo com o conhecimento e os protocolos clínicos do profissional de saúde para ajudar a tomada de decisões de diagnóstico e tratamento. Em outro exemplo, as afecções oncológicas são altamente prevalentes, porém tratáveis se identificadas precocemente, com desafios na abordagem e tratamento distintos para cada tipo de câncer. Uma linha de pesquisa usando IA diz respeito ao uso de redes neurais convolucionais em imagens de cortes histológicos de biópsias de tecidos, visando ajudar a definir as necessidades de métodos de diagnósticos de neoplasias de todo tipo.

Bioinformática – algoritmos, dados e o interior dos seres vivos

A maneira como estudamos as ciências da vida está mudando. O método científico tradicional baseado em descobertas e experimentação dominou até recentemente o modo como cientistas tentam entender a vida. A maioria destes cientistas foi treinada por um método reducionista que partia da ideia de que sistemas complexos ou fenômenos biológicos podiam ser entendidos pela análise de seus componentes mais simples. De acordo com Francis Crick (1966) (citado por Van Regenmortel, 2004, p. 1016): “O objetivo final do movimento moderno da biologia é explicar toda a biologia em termos da física e da química”. Imaginava-se que, para entender como o corpo humano funcionava, precisaríamos entender primeiro o que cada órgão faz, depois cada tecido, cada célula, cada

a fourth dimension, that assesses institutional capacity for municipal management. This fourth area has indicators such as urban planning structure, and information and communication technologies, on-line public services, integration and interoperability of services and digitalization of databases.

Health and agriculture – data, algorithms and computing devices
Health and agriculture are intimately connected, being examples of areas where algorithms, data and new devices are producing important advances. Agriculture is a strategic activity worldwide, which increasingly demands reliable decision making, tailored to animals or plants, performed both over the short and long terms, and developed for specific temporal and spatial scales (local, regional, national and even global). In this context, AI algorithms have been effective for various tasks, including the prediction of crop productivity or the automatic detection of pests. Algorithms and data need to be specific to each solution.

At the same time, the development of new sensors makes data collection more precise and tailored to each location. This is directly connected to the idea of precision agriculture, which uses sensors installed aboard satellites or in farming equipment, or even networks of wireless sensors, for data collection and monitoring. Far from being limited to plant species, the use of sensors and algorithms is also growing for all kinds of livestock (for instance, to increase their comfort, detect diseases, monitor food consumption and even plan their slaughter). Sensors, data and algorithms have expanded to fish farming, hydroponics and other farming activities.

If Computing is crucial for the food production life cycle, it has also become vital for the human life cycle. The health-disease process results from the systemic integration between biological, social and environmental aspects, combining increasingly complex and interrelated transdisciplinary challenges. Nowadays, we understand that disease, more than the consequence of a specific external agent, is intrinsically connected with how we behave and live, as social and biological beings. Health care professionals and patients can benefit from computing solutions, many of which involve Artificial Intelligence. Benefits come both through the increased accuracy of diagnoses and the prediction of risk factors for health and implementation of strategies to reduce the work load of professionals and costs involved.

An example is combatting maternal mortality, and other issues related to women's health, where the vast majority of deaths are avoidable, and result from delays in the provision of adequate care. Data and

algorithms increasingly contribute to facilitating the adoption of guideline recommendations and reinforcing adherence to clinical practices. As such, clinical decision support tools can combine an individual's health information with clinical protocols and knowledge of the health care professional to assist decision making for diagnosis and treatment. Yet another example concerns oncological diseases; while highly prevalent, they are often treatable when identified at an early stage, though still posing challenges in terms of identification and treatment of distinct types of cancer. An associated line of research using AI involves using convolutional neural networks to process images of histological samples of tissue biopsies, aiming to assist in the determination of methodological requirements for diagnosis of all sorts of neoplasms.

Bioinformatics – algorithms, data and the interior of living beings
The way we study Life Sciences is changing. Until recently, the traditional scientific method based on discovery and experimentation dominated the way scientists tried to understand life. The majority of these scientists was trained using a reductionist method based on the idea that complex systems or biological phenomena can be understood through analysis of their simpler components. According to Francis Crick (1966) (as cited in Van Regenmortel, 2004, p. 1016): “The ultimate aim of the modern movement in biology is to explain all biology in terms of physics and chemistry” (Van Regenmortel, 2004). Thus, to understand how the human body worked, we would first of all need to understand what each organ was responsible for, then each tissue, each cell, each molecule and finally each atom (until only mathematics and philosophy remained).

With all the advances in cellular biology and after the discovery of the DNA structure in 1953, we gradually entered the era of molecular biology. The central dogma of that era was that the flow of genetic information started in DNA, was transmitted (transcribed) in a messenger RNA molecule, and then translated into a protein. With the discovery of reverse transcription, ribozymes, riboswitches, chromatin modifications, RNA edition and splicing, microRNA and transcription interference, the central dogma of molecular biology was radically revised. It became clear that cells were operated by very complex regulatory mechanisms.

In 1990, the Human Genome Project was initiated with the aim of sequencing our entire DNA. This ambitious project was equivalent to the Apollo project, which took humans to the moon. It involved the development of new technologies, the sequencing of model organisms, extensive training, discussion of social and ethical implications, and obviously, it led to the

molécula e cada átomo (até restar apenas a matemática e a filosofia).

Com todos os avanços da biologia celular e após a descoberta da estrutura do DNA em 1953, entramos gradualmente para a era da biologia molecular. O dogma central daquela época era que o fluxo da informação genética começava no DNA, era transmitida (transcrita) em uma molécula de RNA mensageiro, que depois era traduzida em uma proteína. Com a descoberta da transcrição reversa, ribozimas, *riboswitches*, modificações da cromatina, edição e *splicing* de RNAs, microRNAs e interferência transcricional, o dogma central da biologia molecular caiu por terra. Ficou claro que as células eram operadas por mecanismos muito complexos de regulação.

Em 1990, o projeto Genoma Humano foi iniciado com o objetivo de sequenciar todas as bases de nucleotídeos de nosso DNA. Este ambicioso projeto era equivalente ao projeto Apollo que levou o homem à Lua e envolveria o desenvolvimento de novas tecnologias, sequenciamento de organismos-modelo, treinamento de pessoal, discussão das implicações éticas e sociais e, claro, culminando no desenvolvimento da Bioinformática. Após o sequenciamento do genoma da bactéria *E. coli* (que tem cerca de 4.700 genes codificadores de proteína), de leveduras (~5.800 genes) e da drosófila (~14.000 genes), foi feita uma aposta entre os cientistas sobre quantos genes codificadores de proteína deveriam existir no genoma humano. As apostas eram muito variáveis, indo de alguns milhares até 1 milhão de genes. “Ora, se uma mosca-da-fruta possui cerca de 14.000 genes, nós, no auge da evolução, deveríamos ter no mínimo 100.000 genes”, era o que muitos pensavam. Com o fim do rascunho do genoma humano em 2001, ficou claro que tínhamos cerca de 25.000 genes codificadores de proteína – muito menos do que o arroz (>50.000 genes). Então, como explicar a complexidade biológica de um ser humano em relação a uma drosófila? Com a descoberta de RNAs não codificadores (tanto microRNAs quanto longos), da epigenética e de outros mecanismos de

Se a Computação é essencial para o ciclo de vida da produção de alimentos, também se tornou fundamental para o ciclo de vida humano.

regulação, ficou mais claro que a complexidade biológica não é explicada pelo número de componentes (genes codificadores de proteína) e sim como eles são finamente regulados.

Graças a revoluções em diversas áreas como a robótica, a nanotecnologia, a óptica e a internet foi possível avançar no desenvolvimento de tecnologias de larga escala aplicadas à biologia molecular. Para se ter uma ideia, o projeto Genoma Humano levou 14 anos e 2,7 bilhões de dólares para revelar as 3,2 bilhões de bases do nosso DNA. Em 2022 é possível sequenciar um genoma humano em poucos dias e por alguns milhares de dólares. Essa revolução genômica nos permitiu mergulhar em projetos grandiosos, como o projeto dos 1.000 Genomas, seguido pelo de 100.000 Genomas e agora o de 1 milhão+ de Genomas. Também embarcamos em projetos que tentam fazer o metagenoma do planeta Terra, assim como obter o perfil transcricional de todos os trilhões de células humanas.

Por meio destas tecnologias de larga escala que envolvem *microarrays*, espectrometria de massa, NMR (ressonância magnética nuclear), dentre outras, tornamo-nos capazes de identificar os principais componentes dos sistemas biológicos. Para cada conjunto destes componentes foi criado um termo com sufixo “oma”. O Genoma representa o conjunto de genes (*loci*) e a própria sequência de cromatina. Transcritoma representa o conjunto de transcritos (ou moléculas de RNA), e Proteoma, o conjunto de proteínas. Metaboloma, Lipidoma e Glicoma representam os conjuntos, respectivamente, de metabólitos, lipídios e carboidratos das células. Outros “omas” foram surgindo que representam conjuntos mais especializados de componentes ou interações biológicas (secretoma, kinoma, interactoma, miRnome, etc.).

Esses avanços só foram possíveis graças à Bioinformática e à Biologia Computacional. Ambos são campos multidisciplinares que envolvem áreas como biologia, estatística, matemática e ciência da computação. A Bioinformática aplica os princípios das ciências de informação e computação

para criar as ferramentas necessárias para analisar, interpretar e processar os milhares de dados biológicos oriundos de observações ou experimentos científicos. Já a Biologia Computacional utiliza essas ferramentas para criar modelos matemáticos e computacionais que ajudam a entender o funcionamento da vida. Apesar de serem complementares e muitas vezes consideradas equivalentes, a Bioinformática e a Biologia Computacional são abordagens distintas.

As aplicações da Bioinformática e Biologia Computacional permeiam todas as áreas das Ciências da Vida. Biotecnologia, descoberta de fármacos, medicina de precisão, terapia gênica, biologia sintética, epidemiologia genômica e modelagem molecular são apenas algumas destas aplicações. E as implicações são igualmente diversas. Tratamentos e diagnósticos para doenças variadas podem ser decididos baseados em análises que usam técnicas computacionais: de reconhecimento de imagens médicas até análise de transcritoma ou de mutações de tumores. A Bioinformática também é essencial para inúmeros projetos de pesquisa básica em Computação, pois utiliza algoritmos de Aprendizado de Máquina, métodos de visualização e software relacionado a análises de larga escala.

Técnicas modernas de edição de genomas são fundamentais para manipulação genética de organismos e de experimentação funcional dos genes. Muitas destas técnicas utilizam o sistema CRISPR (*Clustered Regularly Interspaced Short Palindromic Repeats*), que rendeu o prêmio Nobel de 2020 para as pesquisadoras Emmanuelle Charpentier e Jennifer Doudna. Este sofisticado sistema usa uma endonuclease (Cas9 e agora outras Cas) para clivar regiões específicas do DNA e a inserção de um novo trecho de DNA. O local a ser editado é determinado por uma molécula de RNA (*guide RNA*). Diversas técnicas de Bioinformática permitem o desenho destas moléculas de RNA, avaliam seus efeitos *in vitro* e *in vivo* e podem inclusive prever combinações de genes a serem editados para maximizar seus efeitos.

development of Bioinformatics. After sequencing the genome of *E. coli* bacteria (which has around 4,700 protein coding genes), the genome of yeast (~5,800 genes) and the genome of *Drosophila* (~14,000 genes), scientists made a bet regarding how many protein coding genes the human genome would have. The bets were highly variable, ranging from few thousands up to 1 million genes. Many scientists assumed: “If a fruit fly has around 14,000 genes, we, at the peak of evolution, should have at least 100,000 genes”. With the conclusion of the mapping of the human genome in 2001, it became clear that our species had around 25,000 protein coding genes – much less than rice (>50,000). How could the biological complexity of a human being as compared with *Drosophila* be explained? With the discovery of non-coding RNAs (both microRNAs and long non-coding RNAs), of epigenetics and of other regulatory mechanisms, it became clear that biological complexity is not explained by the number of components (protein coding genes) but by how they are finely regulated.

Thanks to revolutions in different areas such as robotics, nanotechnology, optics and the internet, it was possible to advance the development of large-scale technology applied to molecular biology. While the Human Genome Project took 14 years and 2.7 billion dollars to uncover the 3.2 billion bases of our DNA, in 2022, it is possible to sequence a human genome in a few days paying just a few thousand dollars. This genomic revolution allowed us to start enormous projects, such as the 1,000 genomes project, followed by 100,000 genomes and now 1 million+ genomes. We are also undertaking projects that try to map the metagenome of the whole planet, as well as obtaining the transcription profile of the trillions of human cells.

Through these large-scale technologies that involve microarrays, mass spectroscopy, and nuclear magnetic resonance imaging (NMRI) among others, we can identify the main components of biological systems. For each set of these components a term with the suffix “ome” was created. The Genome represents the set of genes (*loci*) and the chromatin sequence itself. Transcriptome represents the set of transcripts (or RNA molecules), and proteome is the set of proteins. Metabolome, Lipidome and Glycome represent, respectively, the sets of metabolites, lipids and carbohydrates of cells. Other “omes” that represent more specialized sets of biological components or interactions (secretome, kinome, interactome, miRnome etc.) have been suggested.

These advances were only possible thanks to bioinformatics and computational biology. These are multidisciplinary fields that involve areas such as biology, statistics, mathematics and computer science. Bioinformatics applies the principles of computer and information sci-


ence to create the tools necessary for analyzing, interpreting and processing the thousands of biological data produced by observation or scientific experiments. Computational biology uses these tools to create mathematical and computational models that help us understand how life works. Despite being complementary and frequently equivalent, Bioinformatics and Computational Biology are different approaches.

Applications of Bioinformatics and Computational Biology permeate all areas of life sciences. Biotechnology, discovery of drugs, precision medicine, gene therapies, synthetic biology, genomic epidemiology and molecular modelling are only some of these applications. The implications equally have a wide range. Treatments and diagnoses for various diseases can be established based on analyses using computational techniques: from recognizing medical images to analyzing transcriptome or tumoral mutations. Bioinformatics is also crucial for several research projects in Computer Science, since it uses Machine Learning algorithms, visualization methods and software related to large-scale data analysis.

Modern gene editing techniques are fundamental for genetic manipulation of organisms and functional experimentation on genes. Many of these techniques use the Clustered Regularly Interspaced Short Palindromic Repeats (CRISPR) system, with which researchers Emmanuelle Charpentier and Jennifer Doudna won the Nobel Prize in 2020. This sophisticated system uses an endonuclease (Cas9 and now other Cas) to cleave specific regions of DNA and insert a new length of DNA. The site to be edited is determined by an RNA molecule (*guide RNA*). Several Bioinformatics techniques allow the identification of these RNA molecules, assessing their effects *in vitro* and *in vivo* and can even predict gene combinations to be edited to maximize their effects.

Research topics related to Bioinformatics in Brazil range from basic to applied sciences. Frequently, the same methodological approach can be used. For instance, the same comparative genomics (which compares genomes using sequences alignment) can be used to study the evolution of microorganisms (basic science) and to monitor the emergence of viral variants and genomic monitoring (applied science). Machine Learning techniques can be used to process millions of medical texts and extract the relationships between genes, drugs and diseases (basic science) and identify molecular markers whose levels predict the outcome of a disease (applied science). Other examples are related to the analysis of molecular structure, development of drugs and vaccines and the creation of computational tools for molecular data and single cells.

In the near future, it will be difficult to imagine a Life Sciences laboratory that



Os temas de pesquisa relacionados à Bioinformática no Brasil cobrem da ciência básica à aplicada. Muitas vezes, a mesma abordagem metodológica pode ser utilizada. Por exemplo, a mesma genômica comparativa (que compara genomas usando alinhamento de sequências) pode ser usada para estudar a evolução de microrganismos (ciência básica) e para monitorar o surgimento de variantes virais e vigilância genômica (ciência aplicada). Técnicas de Aprendizado de Máquina podem ser usadas para processar milhões de textos médicos e extrair as relações entre genes, fármacos e doenças (ciência básica) e identificar marcadores moleculares cujos níveis predizem o desfecho de uma doença (ciência aplicada). Outros exemplos estão relacionados à análise da estrutura de moléculas, desenvolvimento de fármacos e vacinas e criação de ferramentas computacionais para dados moleculares de células únicas.

Em um futuro próximo, será difícil imaginar um laboratório de Ciências da Vida que não use a Bioinformática em sua pesquisa. Com a constante evolução das tecnologias moleculares, a quantidade de dados gerada por um único laboratório só irá aumentar. Analisar mudanças moleculares ao nível de célula única e de forma espacial e temporal já é uma realidade, assim como determinar a estrutura tridimensional de uma proteína apenas usando sua sequência de aminoácidos (Google’s AlphaFold AI). Com estas ferramentas criadas pela Bioinformática, os cientistas poderão tentar entender a vida.

Por trás dos dados e algoritmos – sinais e otimização

Até agora, esta seção se dedicou a questões associadas a seres vivos (cidades, saúde, agropecuária, bioinformática). Descendo ao nível físico, dados digitais são sinais. As técnicas modernas de processamento de sinais formam um campo do conhecimento bastante vasto, cujas bases foram bem estabelecidas entre os anos 1930 e 1950. Seus resultados, por sua vez, apresentam forte sinergia com várias áreas da Computação.

Esta seção comenta brevemente tais fatos e mostra como a ciência de dados e o Aprendizado de Máquina atuam no processamento de sinais.

Dentre os problemas computacionalmente mais desafiadores em processamento de sinais destacou-se, a partir de meados da década de 1980, o de Separação Cega de Fontes (BSS – *Blind Source Separation*). Ao longo dos anos, a área de BSS recebeu vários aportes até ganhar um arcabouço formal no contexto mais geral de análise de variáveis latentes (LVA – *Latent Variable Analysis*), fortemente relacionado a métodos de decomposição de sinais, tais como a análise por componentes principais (PCA – *Principal Component Analysis*), por componentes independentes (ICA – *Independent Component Analysis*) e por componentes esparsas (SCA – *Sparse Component Analysis*), dentre outros.

Criados no contexto de sinais, os algoritmos associados são ferramentas fundamentais em ciência de dados, nas aplicações em que os dados disponíveis são ruidosos, incompletos ou escassos. Em tais casos, uma das soluções é pré-processamento por meio de estratégias de decomposição para detecção e remoção de ruído, imputação de características ausentes e expansão do conjunto de dados. Estes métodos contribuem ainda como alternativa para a redução de dimensionalidade de dados, fazendo com que a representação obtida retenha as propriedades mais relevantes dos dados originais.

O surgimento de big data e as dificuldades para seu processamento fizeram com que as tomadas de decisão fossem baseadas em modelos, dando origem aos métodos clássicos de apoio à decisão multicritério (MCDA – *Multiple Criteria Decision Analysis*) (Figueira et al., 2005), um ramo da pesquisa operacional que permite resolver problemas de ordenamento, classificação ou seleção de alternativas (Roy, 1985). Nesse contexto, torna-se possível aplicar também ao problema de MCDA o arcabouço teórico de LVA, por meio da hipótese de que o conjunto de dados observados é composto por uma mistura de critérios latentes. As-

does not use Bioinformatics. With the constant evolution of molecular technologies, the amount of data produced by a single laboratory will only increase. Spatially and temporally analyzing molecular changes at the level of a single cell is already a reality, as well as determining the three-dimensional structure of a protein just using exclusively its amino acids sequence (Google’s AlphaFold AI). With these tools created by Bioinformatics, scientists can try to understand life.

Beneath data and algorithms – Signals and optimization
Until now, this section has focused on issues associated with living beings (cities, health, agriculture, bioinformatics). If we descend to the purely physical level, digital data are signals. The modern techniques for signal processing are a fairly vast field of knowledge, whose foundations were well established between the 1930s and 1950s. Their results, in turn, presented a strong connection with various areas in Computing. This section briefly considers such factors and shows how data science and Machine Learning can be used in signal processing.

Since the middle of the 1980s, Blind Source Separation (BSS) stands out as one of the most challenging signal processing computational problems. Over the years, the field of BSS has profited from various contributions, until a formal framework was developed in the more general context of latent variable analysis (LVA). LVA, in turn, is strongly related to signal decomposition methods, such as principal component analysis (PCA), independent component analysis (ICA) and sparse component analysis (SCA), among others.

Created to help solve problems in signal processing, the associated algorithms have become basic tools for data science, in applications where the available data are noisy, incomplete or scarce. In such cases, solutions include pre-processing using decomposition strategies for detection and removal of noise, imputation of absent characteristics, and expansion of the data set. These methods are also used as alternatives to reduce data dimensionality, while ensuring that the reduced representation obtained retains the most relevant properties of the original data.

The emergence of big data and the difficulties in processing such data introduced model-based decision making, leading to classical decision support methods of Multiple Criteria Decision Analysis (MCDA) (Figueira et al., 2005), a branch of operations research that helps solve problems of ordering, classifying or selecting alternatives (Roy, 1985). In this context, it also became possible to apply the LVA theoretical framework, under the hypothesis that the observed data set is constituted by a mixture of latent criteria. Therefore, Machine Learning methods applied to the

analysis of latent variables can be similarly applied to an emblematic problem in signal processing, namely BSS, as well as to the classic optimization problem of decision support systems. We now proceed to further detail these two applications.

The connections between BSS and Machine Learning
As previously noted, the most common approaches in BSS, such as PCA, ICA and SCA, emerge from the broader context of signal decomposition, being used in tasks such as dimensionality reduction and data visualization. In analysis by sparse components, for instance, we take advantage of the fact that the sources to be estimated are constituted by an elevated number of null elements. This allows us to deal with the problem in which the dimensionality of the available data is smaller than that of the sources.

Finally, various recent studies also considered the use of deep learning networks to solve the BSS problem. Such techniques are adequate for cases in which there is a large number of sources, as for instance related to investigation of cerebral activity through the analysis of biological signals. BSS algorithms are also used in bioengineering for signal decomposition in high-density surface electromyography. However, most classical separation methods present limited performance due to the non-stationary character of the signals and the low latency for on-line applications. Such limitations can be mitigated using deep learning techniques.

Machine Learning for multiple criteria optimization
MCDA problems require analysis of multiple criteria that may conflict with one another. Methods to support decision making are being developed to reduce subjectivity, and to aid in the selection of alternatives. From a high level point of view, we can say that the structure of an MCDA problem involves defining the goal and identifying the agents, the alternatives and the criteria involved in the choice. This results in the creation of a decision matrix to which some aggregation method is applied to rank alternatives.

Aggregation is a crucial step in MCDA, in which information about different criteria is processed and combined, producing values to be associated with each alternative. Here, it is possible to see with greater clarity the frontier between the classical methods, in which the estimation is based on models assumed a priori by the decision maker and the methods guided by data, in which Machine Learning plays an important role.

sim, métodos de Aprendizado de Máquina, aplicados à análise de variáveis latentes, adequam-se de forma semelhante a um problema emblemático em processamento de sinais, como o de BSS, e ao caso clássico de otimização, que são os sistemas de apoio à decisão. A seguir detalhamos um pouco mais essas duas aplicações.

As conexões entre BSS e Aprendizado de Máquina

Conforme comentado acima, as abordagens mais utilizadas em BSS, tais como PCA, ICA e SCA, decorrem do contexto mais amplo de decomposição de sinais, sendo empregadas em tarefas como redução de dimensionalidade e visualização de dados. Por exemplo, em análise por componentes esparsas, explora-se o fato de que as fontes a serem estimadas são compostas de um número elevado de elementos nulos. Isto permite tratar o problema em que a dimensão dos dados disponíveis é menor do que a de fontes.

Finalmente, vários trabalhos recentes consideraram ainda o uso de redes profundas para resolver o problema de BSS. Tais técnicas adequam-se a casos de um grande número de fontes, como as relacionadas à atividade cerebral em análise de sinais biológicos. Também em bioengenharia, empregam-se algoritmos de BSS na decomposição dos sinais de eletromiografia de superfície em alta densidade. Entretanto, os métodos mais clássicos de separação apresentam desempenho limitado em virtude da característica não estacionária dos sinais e da baixa latência para aplicações on-line. Tais limitações podem vir a ser mitigadas por meio de técnicas de aprendizado profundo.

Aprendizado de Máquina em otimização multicritério

Em problemas MCDA, existem múltiplos critérios que devem ser considerados, os quais podem ser conflitantes entre si. Métodos de apoio à tomada de decisão vêm sendo desenvolvidos de modo a diminuir a subjetividade e auxiliar na seleção das alternativas. De forma resumida, podemos dizer que a estrutura de um proble-

Em um futuro próximo, será difícil imaginar um laboratório de Ciências da Vida que não use a Bioinformática em sua pesquisa.

ma MCDA consiste em definir o objetivo e identificar os agentes, as alternativas e os critérios envolvidos na escolha. Com isso, cria-se uma matriz de decisão à qual se aplica algum método de agregação para ordenar as alternativas.

A agregação é a etapa fundamental em MCDA, na qual informações sobre os diferentes critérios são processadas e combinadas, gerando valores a serem associados a cada alternativa. Neste ponto aparece de forma mais clara a fronteira entre os métodos clássicos, nos quais a estimação é baseada em modelos assumidos *a priori* pelo decisor e os métodos orientados por dados, nos quais o Aprendizado de Máquina passa a exercer um papel importante.

NOVOS TIPOS DE HARDWARE E TECNOLOGIAS EXPONENCIAIS

Num capítulo sobre Computação, não podemos deixar de mencionar as plataformas computacionais, que normalmente chamamos de hardware. Computadores primitivos antes do século 20 eram implementados utilizando sistemas mecânicos. A partir do século 19 começamos a implementá-los com a eletrônica, inicialmente com válvulas termoiônicas; a partir da invenção do transistor em 1947, uma nova ferramenta surgiu para implementar computadores de grande complexidade: a microeletrônica.

A Computação vem evoluindo em ciclos interativos cada vez mais velozes entre dados, algoritmos e hardware. Desde o sistema binário de Leibniz, passando por Charles Babbage, chamado “pai da computação”, Ada Lovelace, a primeira programadora, nos anos 1840, com programação baseada na máquina de Babbage, Turing, que formalizou a noção de algoritmos e de computação na primeira metade do século 20, e finalmente a convergência para a máquina de Von Neumann, que consolidou a arquitetura de computadores utilizada até hoje. A invenção do transistor (trans-resistor) com tecnologia bipolar em 1947 por Bardeen, Shockley e Brattain, e Prêmio Nobel de Física em 1956, foi um passo importante

NEW KINDS OF HARDWARE AND EXPONENTIAL TECHNOLOGIES

In a chapter on Computing, we must mention computational platforms, usually called hardware. Primitive computers, before the 20th century, were implemented using mechanical systems. From the 19th century on, they began to be implemented with electronics, initially with thermionic valves. Beginning with the invention of the transistor in 1947, a new tool emerged to build high complexity computers: microelectronics.

Computing is evolving through increasingly fast interactive cycles intertwining data, algorithms and hardware. We can say it all began with Leibniz's binary system, followed by Charles Babbage, the so-called “father of the modern computer”, and Ada Lovelace, the first computer programmer, in the 1840s, whose programs were based on the Babbage machine. Then, almost 100 years later came Turing, who formalized the idea of algorithms and computation in the first half of the 20th century, finally converging towards the Von Neumann architecture, which consolidated the computer architecture adopted until today. The invention of the transistor (trans-resistor) with bipolar technology, in 1947, by Bardeen, Shockley and Brattain – and their ensuing Nobel Prize for Physics in 1956 – was an important step in establishing complex computational machines, making it possible to produce smaller, more complex computers. Also from a historical perspective, the formalization of modern signal processing techniques and of linear filtering became a well-established field of investigation, mainly between the 1930s and 1950s (see section ‘Beneath data and algorithms – Data and Optimization’ this chapter).

The intrinsic and robust association between Boolean algebra and transistor behavior as a binary switch was quickly noted. This allowed the construction of increasingly complex, robust and miniaturized computers starting from the 1950s. During the 1960s, there appeared the first interactive computer programs for Computer Aided Design (CAD), allowing humans to use computers to design more advanced computers. From this moment onward, exponential behavior from computing/electronics was observed, culminating in the article by Gordon Moore (Moore, 1965) that states the famous “Moore's law”. This “law” is a statement of an empirical observation that the complexity of integrated circuits doubles every 18 months. Associated with complexity, two other parameters for Moore's law are relevant: computers' physical dimensions and energy consumption.


Moore's law has persisted for more than 50 years, and probably will continue to do so for decades to come. Nowadays, new microprocessors are specified through programming languages. That is, the mi-

croprocessor is described as a computer program, which is then compiled into silicon, through a microelectronics manufacturing process. Physical computational machines are compiled from code that describes them and are subsequently synthesized for fabrication. In other words, hardware began to be built from algorithms and data.

Another way to interpret Moore's law is to consider the complexity and dimensions of a computer to be constant. From this point of view, this virtuous cycle of Moore's law is allowing the construction of a wide range of cheaper, increasingly complex, miniaturized computers with lower energy consumption. For instance, the current human population is of approximately 7.5 billion individuals. Suppose that each person has at this moment a smartphone device with 2 Gbytes of RAM, four 64-bit processors and 64 Gbytes of local storage. Assuming an operating system that could manage this distributed meta computer, there would currently be available 15 Exabytes (10^{18}) of volatile memory, 30 billion CPUs and 480 Exabytes of storage. We know, however, that the number of computational resources currently available is much greater, since our meta computer does not include computers integrated into all sorts of objects (such as cars, refrigerators, airplanes or satellites), nor computers available in data or supercomputing centers (and associated High-Performance Computing). Certainly, by the 2030s, humanity will be able to construct machines with a capacity of Zettabytes (10^{21}), and, by 2040, of Yottabytes (10^{24}), if Moore's law persists.

The exponential availability of computers and democratized access to programming occurs simultaneously with the mass dissemination of programming throughout the world. At the exact moment this chapter is being read, tens of millions of people are specifying algorithms, programming computers and designing integrated circuits using software. The evolution of programming techniques over recent decades has also been notable and changed the way humans symbolically represent reality through mathematical models.

With the consolidation of Complementary Metal-Oxide-Semiconductor (CMOS) technology, the last 50 years have witnessed significant progress in microelectronics-based computer architecture design. This technology allows the implementation of transistors and other electronic structures based on superimposed layers of conductors (metals), insulators (silicon oxide) and enriched semiconductors (normally silicon enriched with boron and phosphorous). CMOS has made possible the integration of microprocessors, memories and other computational systems for Very Large Scale Integration (VLSI) chips. Currently, more than 99% of microprocessors are implemented with CMOS. Microprocessor integrated circuits built



© MFS3D / ISTOCKPHOTO.COM

para a concretização de máquinas computacionais complexas, viabilizando computadores menores e mais complexos. Ainda numa perspectiva histórica, a formalização das técnicas modernas de processamento de sinais e de filtragem linear tornou-se um campo bem estabelecido do conhecimento, principalmente entre as décadas de 1930 e 1950 (ver seção “Por trás dos dados e algoritmos – Sinais e otimização”).

Rapidamente constatou-se a associação intrínseca e robusta entre a álgebra booleana e o comportamento do transistor como chave binária, permitindo a partir da década de 1950 a construção de computadores transistorizados cada vez mais complexos, robustos e miniaturizados. Na década de 1960, surgiram os primeiros programas de computador interativos para projeto auxiliado por computador (CAD – *Computer Aided Design*), permitindo que humanos usassem os computadores para projetar computadores mais avançados. A partir deste momento observa-se um comportamento exponencial da computação/eletrônica, culminando no artigo de Gordon Moore (Moore, 1965), que propõe a famosa “lei de Moore”. Esta “lei” é uma constatação empírica de que a complexidade da eletrônica/computação dobra a cada 18 meses. Associados à complexidade, pode-se considerar dois outros parâmetros à lei de Moore: a dimensão física e o consumo de energia dos computadores.

A lei de Moore persiste há mais de 50 anos, e provavelmente vai perdurar por mais décadas. Hoje, novos microprocessadores são descritos por linguagens de programação, ou seja, o microprocessador é descrito como um programa de computador, que depois é compilado para o silício, considerando um processo de fabricação de microeletrônica. Máquinas computacionais físicas são compiladas a partir de código que as descreve e posteriormente sintetizadas para fabricação. Em outras palavras, o hardware passou a ser criado a partir de algoritmos e dados.

Uma outra forma de interpretar a lei de Moore é considerar a complexidade e dimensão de um computador constantes; sob este ponto de vista, pode-se construir

computadores mais baratos e com menor consumo de energia. Este ciclo virtuoso da lei de Moore vem permitindo a construção de todo um amplo espectro de computadores cada vez mais complexos, miniaturizados e com menor consumo de energia. Para exemplificar, a humanidade hoje possui aproximadamente 7,5 bilhões de humanos. Suponhamos que cada humano possui, neste instante, um aparelho celular modelo smartphone com 2 Gbytes de RAM, 4 núcleos de processamento de 64 bits e 64 Gbytes de armazenamento local. Imaginando, por hipótese, um sistema operacional para gerenciar este metacomputador distribuído, teríamos à disposição hoje 15 Exabytes (10^{18}) de memória volátil, 30 bilhões de CPUs e 480 Exabytes de memória de armazenamento. Sabemos, no entanto, que este número de recursos computacionais disponíveis atualmente é muito maior, pois não estamos contabilizando os computadores embarcados em todo tipo de objeto (como carros, geladeiras, aviões ou satélites), nem tampouco computadores disponibilizados em supercentros de dados ou de processamento (e a associada *High Performance Computing*, a computação de alto desempenho). Certamente até a década de 2030 a humanidade será capaz de construir máquinas com capacidade de Zettabytes (10^{21}), e em 2040, Yottabytes (10^{24}), se a lei de Moore perdurar.

A oferta exponencial de computadores e o acesso democratizado à programação ocorreram de forma concomitante com a disseminação massiva da programação pelo mundo – neste exato momento em que este capítulo está sendo lido, dezenas de milhões de humanos estão especificando algoritmos, programando computadores e projetando circuitos integrados usando software. A evolução das técnicas de programação nas últimas décadas foi também expressiva e mudou a forma como até então os humanos representam simbolicamente a realidade a partir de modelos matemáticos.

Nos últimos 50 anos, as técnicas de projeto de computadores pela microeletrônica tiveram avanços significativos, com a consolidação da tecnologia CMOS (*Com-*

in 2021 use tens to hundreds of millions of CMOS transistors in which the smallest physical dimension is of the order of 2 nanometers. Just for comparison, the COVID-19 coronavirus measures between 50 and 140 nanometers.

This vast dissemination of computers in and beyond our planet (on satellites and spaceships) has created new computational dimensions, among them cyberphysics, an emerging branch of Computing, where computation (cyber) strongly interweaves with the real world (physics). Cyberphysical systems include virtually all the computational topics considered in this chapter, in strong interaction with physical systems.

Promising, new technologies are emerging to implement computers. These include photonics, in which photons are used instead of electrons; spintronics, which explores the quantum behavior of electron magnetic orientation (spin), and more recently, quantum computers have begun to be implemented. Currently, the existence of humans without computers is unimaginable. Computing is present in nearly every domain of human life and, in a few years, humanity will probably have trillions of interconnected computers.

Computational tasks in the future will essentially depend on the human ability to model, program and synthesize more and more computers in a sustainable and ethical manner. Basically, these abstraction, modelling and synthesis cycles define computing as a form of “procedural epistemology” (Fry, 1985).

HUMAN, SOCIAL AND ECONOMIC IMPACTS
Until now, we have seen examples of how digital technologies are crucial to understand the past and build the future. An article in Nature (Sachs et al., 2019) discusses which transformations the signatory countries of the Paris Agreement should consider to achieve the 17 Sustainable Development Goals (SDGs). These transformations will require complementary initiatives from governments, civil society, the private sector, universities and various other sectors. The article proposes six transformations as fundamental blocks to attain these objectives. (1) education, gender and inequality; (2) health, well-being and demographics; (3) decarbonized energy and sustainable industry; (4) sustainable food, land, water and oceans; (5) sustainable cities and communities; and (6) digital revolution for sustainable development.

The digital revolution for sustainable development includes AI and other digital technologies, such as the Internet of things (IoT), robotics, blockchain and others. These are technologies whose impacts are felt in nearly all sectors of the economy, including precision agriculture, autonomous vehicles, e-commerce, electronic payments, negotiation strategies,

social networks, automated diagnoses, telemedicine, on-line learning, electronic governance, electronic voting and science and technology themselves. The potential benefits of digital technologies are numerous. They can bring innovation, efficiency, competitiveness and cost reduction to society and the economy, as well as make public services more transparent, accessible and efficient.

In one of his declarations, the UN Secretary-General emphasized that following the “tragedy and danger” of the pandemic, sustainable development goals were more important than ever to put the world back on the right track. In his message, Guterres outlined ten urgent priorities for the future (United Nations, 2021). Among these priorities was the need to make use of the opportunities offered by digital technologies and, at the same time, protect against their growing dangers.

Many are the benefits, but also countless the possibilities of negative impacts from the accelerated digitalization of society, including economic, political and social effects. The absence of adequate public policy can increase digital exclusion, in which part of the global population does not have access to the benefits that come with digital technologies. Maybe the most feared risk from the advance of AI would be losing jobs, especially for less qualified workers. The Nobel Prize winner in economic sciences, Joseph Stiglitz, outlined a pessimistic scenario for developing nations, such as Brazil (Korinek & Stiglitz, 2021). The following reasons underpin Stiglitz’s position. The potential of AI to save labor will have a greater impact on countries with labor intensive production and exportation sectors. The potential of AI to save natural resources should impact countries that export natural resources, while benefiting importing countries. The concentration of power tends to increase in the few companies and countries that dominate AI technologies, the so-called “big techs”, leading to greater economic inequality. Other threats from the digital advance include invasion of privacy by governments or companies, discrimination based on personal data, digital propagation of hate speech, and discrimination and misinformation through social media platforms and services, allowing political manipulation and generating polarization and conflict in various regions and countries. The concentration of control over society is not necessarily in the hands of the state – neither in developed countries, nor in developing ones, as in the Brazilian case. The financial system and big technology companies hold detailed information about all of us, highlighting the need for society to expand the discussion about data regulation and its limits.

Given the accelerated advance of digitalization of society, with its benefits and threats, an important issue arises: what is

plementary Metal–Oxide–Semiconductor). Esta tecnologia permite a implementação de transistores e outras estruturas eletrônicas a partir da sobreposição de camadas de condutores (metais), isolantes (óxido de silício) e semicondutores enriquecidos (normalmente silício enriquecido com boro e fósforo). A CMOS viabilizou a integração de microprocessadores, memórias e outros sistemas computacionais em ultra escala VLSI (*Very Large Scale Integration*). Atualmente, mais de 99% dos microprocessadores são implementados em CMOS. Circuitos integrados de microprocessadores implementados em 2021 utilizam dezenas a centenas de milhões de transistores CMOS em que a menor dimensão física é da ordem de 2 nanômetros; para se ter uma ideia dimensional, o vírus da covid-19 mede entre 50 e 140 nanômetros.

Esta vasta disseminação de computadores no nosso planeta e fora dele (em satélites e naves espaciais) tem criado novas dimensões computacionais, dentre elas a ciberfísica, um ramo emergente da Computação, em que a computação (ciber) começa a se entrelaçar fortemente com o mundo real (física). Sistemas ciberfísicos englobam praticamente todos os temas computacionais abordados neste artigo em forte interação com sistemas físicos.

Novas tecnologias promissoras estão surgindo para implementar computadores, como a fotônica, em que utilizamos fótons em vez de elétrons, a spintrônica, que explora o comportamento quântico da orientação magnética (spin) do elétron, e mais recentemente computadores quânticos começam a ser implementados. Atualmente não conseguimos imaginar a humanidade sem a existência de computadores. A computação se manifesta em praticamente todos os domínios da vida humana; provavelmente, em poucos anos, a humanidade alcançará o número de trilhões de computadores interconectados.

A computação no futuro dependerá essencialmente da capacidade humana de modelar, programar e sintetizar mais e mais computadores de forma sustentável e ética. Essencialmente estes ciclos de

Esta vasta disseminação de computadores no nosso planeta e fora dele (em satélites e naves espaciais) tem criado novas dimensões computacionais, dentre elas a ciberfísica, um ramo emergente da Computação (...)

abstração, modelagem e síntese definem a computação como uma forma de “epistemologia procedural” (Fry, 1985).

IMPACTOS HUMANOS, SOCIAIS E ECONÔMICOS

Vimos até agora exemplos de como as tecnologias digitais são um eixo fundamental para entender o passado e na construção do futuro. Um artigo da revista *Nature* (Sachs et al., 2019) discute quais transformações os países signatários do Acordo de Paris devem considerar para atingir as metas acordadas para os 17 Objetivos de Desenvolvimento Sustentável (ODS). São transformações que irão exigir iniciativas complementares de governos, sociedade civil, empresas, universidades e vários outros setores. O artigo propõe seis transformações como blocos fundamentais para realização dos objetivos. (1) educação, gênero e desigualdade; (2) saúde, bem-estar e demografia; (3) descarbonização de energia e indústria sustentável; (4) alimentos, terras, água e oceanos sustentáveis; (5) cidades e comunidades sustentáveis; e (6) revolução digital para o desenvolvimento sustentável.

A revolução digital para o desenvolvimento sustentável inclui inteligência artificial (IA) e outras tecnologias digitais, como internet das coisas (IoT), robótica, *blockchain* e outras. São tecnologias com impacto em quase todos os setores da economia, incluindo agricultura de precisão, veículos autônomos, *e-commerce*, pagamentos eletrônicos, estratégias de negociação, redes sociais, diagnósticos automatizados, telemedicina, aprendizagem on-line, governança eletrônica, votação eletrônica e a própria ciência e tecnologia. Os potenciais benefícios das tecnologias digitais são múltiplos. Elas podem trazer inovação, eficiência, competitividade e redução de custos para a sociedade e a economia. Podem tornar os serviços públicos mais transparentes, disponíveis e eficientes.

Em uma de suas declarações, o secretário-geral da ONU enfatizou que depois da “tragédia e perigo” da pandemia, os objetivos do desenvolvimento sustentável são

mais importantes do que nunca para colocar o mundo no caminho certo. Em sua mensagem, o secretário-geral delineou dez prioridades urgentes para o futuro (United Nations, 2021). Dentre elas, está a necessidade de se aproveitar as oportunidades das tecnologias digitais e, ao mesmo tempo, se proteger contra seus perigos crescentes.

Os benefícios são incontáveis, mas são muitas, também, as possibilidades de impacto negativo da acelerada digitalização da sociedade. Impactos econômicos, políticos e sociais. A ausência de políticas públicas adequadas pode ampliar a exclusão digital, em que parte da população global não tem acesso aos benefícios trazidos pelas tecnologias digitais. Talvez o risco mais temido do avanço da IA seja a perda de empregos, especialmente para trabalhadores menos qualificados. O prêmio Nobel de Economia Joseph Stiglitz traçou um cenário pessimista para os países em desenvolvimento, como o Brasil (Korinek & Stiglitz, 2021). São as seguintes razões que reforçam essa posição de Stiglitz. O potencial da IA para economizar mão de obra terá maior impacto em países com setores de produção e exportação intensivos em mão de obra. O potencial de IA para economizar recursos naturais deverá causar impacto para os países exportadores de recursos naturais, mas com benefícios para os importadores. A concentração de poder tende a aumentar nas poucas empresas e nos países que dominam as tecnologias de IA, as chamadas “big tech”, levando a uma maior desigualdade econômica. Outras ameaças do avanço digital incluem invasão de privacidade por governos ou empresas, discriminação com base em dados pessoais, propagação digital de discursos de ódio, discriminação e desinformação por meio das plataformas de mídias sociais e serviços, possibilitando manipulações políticas e gerando polarização e conflitos em várias regiões e países. A concentração do poder de controle sobre a sociedade não está necessariamente nas mãos do Estado – nem nos países desenvolvidos, nem nos países em desenvolvimento, como o caso brasileiro. O sistema financeiro e as grandes empresas de tecno-

the role of Computer Science in times when the digital is present in nearly all aspects of contemporary life. Today's citizens interact multiple times a day with numerous platforms such as Google, YouTube, Spotify, Twitter and others. The modern individual shops on Amazon, participates in the LinkedIn professional community, uses Uber or Waze for transport, or Tinder to look for romantic relationships. These services are important and practical for users who sufficiently trust the algorithms, many of them AI algorithms that control the logic of the apps, to the point of delegating to them the choice of preferences, curricula, means of transport and affective relationships. The Chinese government, for example, has created projects that give their citizens a “social ranking”, in which the algorithm classifies a citizen as a desirable worker, a reliable tenant, a valuable client – or as a fraudster, unreliable or unproductive person (Kostka, 2019). As a consequence, social benefits and resources are assigned according to that score. The replacement of humans by algorithms or the use of algorithms for making decisions regarding citizens should evidently undergo ample scrutiny by society. There are numerous issues, including the transparency of algorithms and the reasons for the delegation of decisions to an automated system instead of to humans. They also include the social impacts of automation and the meaning of individual and collective decision-making processes, which could suffer from dehumanization. The analysis of the attribution of responsibility to automated systems is also pertinent. It is precisely in the context of the need to understand algorithmic decision-making systems that Computer Science can and should also make a contribution.

High risk decisions based on algorithmic systems are on one hand characterized by efficiency and speed that can accelerate currently extremely slow processes, as those of the Brazilian justice system, for instance. On the other hand, such automatic decisions can have unintended consequences, caused by complex and opaque algorithms, and/or biased or non-diverse data. Such effects can be harmful, mainly to more vulnerable groups. Research in Computing can contribute to minimize errors and undesired consequences of AI algorithms, as well as to identify problems with social and political impacts.

An article by Abebe et al. (2020) maps four structural forms in which Computer Science can contribute to identify social problems resulting from advances in AI and in algorithmic processes for decision making. These are usually complex and opaque processes, whose transparency and responsibility cannot in the majority of cases be grasped nor understood by society. This issue is particularly important in the Brazilian context, where the transition to a digitalized so-

cietiy takes place rapidly and within a still underdeveloped legal framework. The article identifies functions in which Computing research can focus to identify social impacts and their risks: diagnosis, formalization, refutation and synecdoche. These functions can be adapted and expanded to show how Computing has the potential to contribute to the identification of social impacts resulting from the digitalization of society.

Diagnosis of social problems manifested in sociotechnical systems Computing can contribute to diagnosing social problems resulting from sociotechnical systems, such as digital platforms. The term “sociotechnical” refers to ways in which social actors and technological artifacts become intertwined as parts of unified systems – instead of discrete entities (Suchman et al., 1999). An article by Harvard professor Latanya Sweeney (Sweeney, 2013) shows that technology can lead to discriminatory outcomes, but can also stop undesired discrimination. Sweeney shows, using Google search mechanisms, that search for people whose names indicate that they might be black are more likely to associate them with advertisements that suggest criminal records, which does not occur with names that indicate white people. She collected evidence analyzing more than 2,000 names searched for that suggest race for this empirical study, which confirmed the initial hypothesis of racism. The article shows how Computing can be used to diagnose social problems - racism in this case. Her paper points out that the main steps that can be taken in empirical studies to identify discriminatory algorithms are: (1) identify the groups affected; (2) specify the scope of interventions to be assessed; (3) determine the feeling and the action of the intervention; and (4) verify the occurrence of adverse impacts.

Refutation Computing can contribute to understanding the limits of digital interventions and policies based on them. The goal of the American government's Extreme Vetting Initiative was to carry out automated predictions about the possibility of an immigrant “intending to commit” terrorism or other crimes in the future. Various sectors of civil society, including a group of computer scientists, opposed this initiative of the Department of Homeland Security (DHS) affirming that it was not only discriminatory, but also technically unfeasible (Duarte, 2017).

No computational method can provide reliable or objective assessment of the characteristics the program sought to quantify. Very likely, the proposed system would be imprecise and biased. Scientists refuted the idea of the project, recommending that the government reconsider its implementation.

logia possuem informações detalhadas sobre todos nós, indicando para a sociedade a necessidade de ampliar a discussão sobre regulamentação de dados e seus limites.

Frente ao avanço acelerado da digitalização da sociedade, com seus benefícios e ameaças, emerge uma questão importante: qual o papel da Ciência da Computação nestes tempos em que o digital está presente em todos aspectos da vida contemporânea. O cidadão dos tempos atuais interage várias vezes ao dia com inúmeras plataformas como Google, YouTube, Spotify, Twitter e outras. O indivíduo contemporâneo faz compras na Amazon, participa da comunidade profissional do LinkedIn, usa o Uber ou Waze para transporte ou recorre ao Tinder para a busca de relacionamentos amorosos. Estes serviços são importantes e práticos para os usuários, que confiam o suficiente nos algoritmos, muitos deles algoritmos de IA, que regem a lógica destes aplicativos, a ponto de delegar-lhes gostos, currículos, meio de transporte e preferências afetivas. O governo chinês, por exemplo, trabalha com projetos para atribuir aos seus cidadãos uma “pontuação social”, em que um algoritmo classifica os cidadãos como um funcionário desejável, inquilino confiável, cliente valioso – ou um caloteiro, esquivo ou improdutivo (Kostka, 2019). Como consequência, benefícios e recursos sociais estarão associados a essa pontuação. A substituição de humanos por algoritmos ou o uso de algoritmos para decisões sobre os cidadãos devem necessariamente passar por amplas discussões na sociedade. As questões são várias. Incluem a transparência dos algoritmos e as razões para a delegação de decisões a um sistema automatizado em vez de humano. Incluem também os impactos sociais da automação e o significado dos processos decisórios individuais e coletivos, que poderiam estar sendo desumanizados e a definição de responsabilidades dos sistemas automatizados. E é justamente no contexto da necessidade de entender os sistemas de decisão algorítmica que a Ciência da Computação pode e deve também dar sua contribuição.

Decisões de alto risco baseadas em sistemas algorítmicos têm por um lado a característica da eficiência e da rapidez, que podem acelerar processos hoje extremamente lentos, por exemplo, os processos na justiça brasileira. Por outro lado, tais decisões automáticas podem ter efeitos não esperados, em inglês “*unintended consequences*”, causados por algoritmos complexos e opacos e/ou por dados enviados ou pouco diversos. Tais efeitos podem ser danosos, principalmente a grupos mais vulneráveis da sociedade. A pesquisa em Computação pode tanto contribuir para minimizar erros e consequências não desejadas de algoritmos de IA, como também atuar na identificação de problemas com impacto social e político.

Um artigo de Abebe et al. (2020) mapeia quatro formas estruturais em que a Ciência da Computação pode contribuir para identificar problemas sociais decorrentes do avanço da IA e dos processos algorítmicos de tomada de decisão. São em geral processos complexos e opacos, cuja transparência e responsabilidade estão na maior parte dos casos fora do alcance e compreensão da sociedade. Essa questão é particularmente importante no contexto brasileiro, onde a transição para uma sociedade digitalizada ocorre rapidamente e com um arcabouço legal ainda pouco desenvolvido. O artigo articula funções que a pesquisa em Computação pode focalizar na busca da identificação de impactos sociais e seus riscos: diagnóstico, formalização, refutação e sinédoque. Essas funções podem ser adaptadas e expandidas para mostrar como a Computação tem o potencial para contribuir na identificação de impactos sociais decorrentes da digitalização da sociedade.

Diagnóstico de problemas sociais manifestados em sistemas sociotécnicos

A Computação pode contribuir para diagnosticar problemas sociais decorrentes dos sistemas sociotécnicos, como as plataformas digitais. O termo “sociotécnico” refere-se a formas pelas quais atores sociais e artefatos tecnológicos tornam-se entrelaçados como parte de sistemas

unificados – em vez de discretos (Suchman et al., 1999). Um artigo da professora de Harvard Latanya Sweeney (Sweeney, 2013) mostra que a tecnologia pode promover resultados discriminatórios, mas também que a tecnologia pode impedir a discriminação indesejada. A professora mostra, usando buscas do Google, que pessoas cujos nomes indicam que podem ser negras têm mais probabilidade de serem alvos de anúncios que sugerem um registro criminal, algo que não ocorre com nomes que indicam pessoas brancas. Ela coletou evidências analisando mais de 2.000 nomes que sugerem raça para o estudo empírico, que confirmou a hipótese inicial de racismo. O artigo mostra como a Computação pode ser usada para diagnosticar problemas sociais, racismo no caso do artigo. Destaca que os passos principais que podem ser seguidos em estudos empíricos para identificação de algoritmos que discriminam são: (1) identificar os grupos afetados; (2) especificar o escopo das intervenções a serem avaliadas; (3) determinar o sentimento e a ação da intervenção; e (4) verificar a ocorrência de impacto adverso.

Refutação

A Computação pode contribuir para a compreensão dos limites de intervenções digitais e de políticas baseadas nelas. O projeto “Extreme Vetting Initiative” do governo americano tinha como objetivo fazer previsões automatizadas sobre a possibilidade de um imigrante “pretender cometer” terrorismo ou outro crime no futuro. Vários setores da sociedade civil, incluindo um grupo de cientistas da computação, se colocaram contrários à iniciativa do Departamento de Segurança Interna (DHS), afirmando que iniciativa não era apenas discriminatória, mas também tecnicamente inviável (Duarte, 2017).

Nenhum método computacional pode fornecer avaliações confiáveis ou objetivas das características que o programa procurava medir. Muito provavelmente, o sistema proposto seria impreciso e tendencioso. Os cientistas refutaram a ideia

do projeto, recomendando ao governo reconsiderar o projeto.

Formalização

A Computação requer a especificação explícita das entradas, saídas e objetivos dos algoritmos para poder compreender os impactos humanos e sociais de decisões algorítmicas. Um estudo publicado por Obermeyer e colegas (Obermeyer et al., 2019) relata a análise das saídas e entradas de um algoritmo que prevê o risco de saúde e influencia o tratamento de milhões de pessoas. O estudo mostra que o algoritmo usa o custo do atendimento como um substituto (i.e., “proxy”) para as necessidades de tratamento de saúde. Para pacientes negros e pacientes brancos internados com o mesmo nível de risco, o algoritmo atribui um orçamento menor para o tratamento dos pacientes negros, com consequente impacto para a saúde desses pacientes. O artigo mostra que um algoritmo amplamente utilizado nos serviços de saúde afetou milhões de pacientes, exibindo claramente um viés racial significativo.

Detecção de questões sociais

A Computação pode evidenciar e trazer para o primeiro plano problemas sociais e políticos decorrentes da digitalização da sociedade. Um artigo publicado por pesquisadores brasileiros (Resende et al., 2019) analisa a disseminação de informações dentro do WhatsApp, com foco em grupos de orientação política, publicamente acessíveis por meio de imagens coletadas e compartilhadas durante dois eventos marcantes no Brasil: a greve nacional de caminhoneiros e a campanha presidencial brasileira. Em ambos os casos, o estudo identifica a presença de desinformação nas imagens compartilhadas. Esse trabalho teve o papel de detector de questões políticas e sociais, que foram a distribuição de imagens falsas em situações críticas para a democracia brasileira. O estudo tornou-se uma importante referência para estabelecimento de regulamentações eleitorais (Tribunal Superior Eleitoral, 2020).

Formalization
Computing requires the explicit specification of inputs, outputs and objectives of algorithms to understand the human and social impacts of algorithmic decisions. A study published by Obermeyer and colleagues (Obermeyer et al., 2019) reports the analysis of outputs and inputs of an algorithm that predicts health risks, and influences the treatment of millions of people. The study shows that the algorithm uses the cost of the treatment as a proxy for the health care needs of the patient. For black and white patients hospitalized with the same risk level, the algorithm assigns a lower budget for the treatment of black patients, with consequent impacts on the health of these patients. The article shows that an algorithm widely used in health care services affected millions of patients, clearly demonstrating a significant racial bias.

Detection of social issues
Computing can show and bring to the foreground social and political problems resulting from the digitalization of society. An article published by Brazilian researchers (Resende et al., 2019) analyzes the dissemination of information via WhatsApp, focused on politically oriented groups, publicly accessible through images collected and shared during two notable events in Brazil: the national truckers’ strike and the Brazilian presidential campaign. In both cases, the study identified the presence of misinformation in the images shared. This study was able to detect political and social issues of the distribution of fake images during critical situations for the Brazilian democracy. The study became an important reference for the establishment of electoral regulations (Tribunal Superior Eleitoral, 2020).

DATA AND ALGORITHM ETHICS – A NEW FIELD OF KNOWLEDGE

The concerns just discussed raise important ethical issues. The notion of ethics in developing computational systems (both software and hardware) is well established, but became critical with the so-called “data deluge” and the consequent rebirth of AI algorithms. One of the first codes of ethics for Computer Science, dating from 1992, was proposed by the Association for Computing Machinery (ACM), the USA computer society (ACM Committee on Professional Ethics, 1992). This was followed by proposals from other scientific societies in the area. Among them, it is worth mentioning the 2013 code of the Brazilian Computer Society, whose ethics committee dates from the same period. The current ACM code, approved in 2018, has a clause that reflects present concerns with responsible practices for data use (and collection), and for the creation of algorithms and programs – “[...] 3.7 Recognize and take special care of sys-

tems that become integrated into the infrastructure of society.” (ACM Committee on Professional Ethics, 2018).

The terms “data ethics” and “algorithm ethics” are usually considered in two moments. The first category investigates activities associated with the data life cycle, including concerns about how to avoid discrimination or distortion in data collection that leads to biased decisions and algorithms – as mentioned in the previous section. Ethics for the specification and implementation of algorithms refers to issues that, when executing an algorithm, produce discrimination, cause physical or moral harm, invade the privacy of people, or propagate fake news, among others. These issues are at the heart of specific graduate courses and research centers dedicated to studying these aspects, always involving collaboration among philosophers, humanists and computer scientists, such as at the Big Data Institute (Big Data Institute, 2017) at Oxford University.

As this chapter shows, the borders between data and algorithms are increasingly tenuous, in particular in AI, where data induce the models that in turn produce more data. Ethics associated with data and algorithms (O’Neil, 2016), combined with the recent popularization of Machine Learning algorithms, have increased concerns about AI-generated models, thereby originating a research area named “responsible artificial intelligence”.

Responsible AI includes all aspects that should be observed during the data life cycle as well as the models themselves, which should be ethical and equitable, and not embed any form of prejudice, while also being transparent. In numerous situations, many of the irresponsible or anti-ethical behaviors of models are due to the patterns that exist in the data set used to generate them. In order for AI to have a positive impact on our lives, it should follow the premises that guide its use in this direction. This is reflected in the UNESCO recommendations on ethics in AI, approved in November 2021 (United Nations Educational, Scientific and Cultural Organization, 2021).

As seen throughout this chapter, algorithmic systems bring multiple benefits. However, given the accelerated expansion of services operated by algorithms, there is a growing concern in society about the adoption of algorithms in sensitive areas, such as health care services (Muller et al., 2021), predictive policing, facial identification, and allocation of social benefit concessions, among others. Given that there is no going back from the advances of digitalization, it is important to create mechanisms to prevent the adverse consequences of algorithmic systems. Such mechanisms rely on public policy and the regulation of algorithmic systems, especially AI systems. Computing has a vital role in these new times of digitalized societies; research and development in Com-

ÉTICA NO USO DE DADOS E ALGORITMOS – UM NOVO RAMO DO CONHECIMENTO

Essas preocupações levam a questões éticas importantes. A noção de ética no desenvolvimento de sistemas computacionais (tanto software quanto hardware) é antiga, mas se tornou premente com o chamado “dilúvio de dados” e o consequente renascimento dos algoritmos de IA. Um dos primeiros códigos de ética em Computação, datando de 1992, foi proposto pela ACM (Association of Computing Machinery), a sociedade americana de Computação (ACM Committee on Professional Ethics, 1992), sendo seguido por propostas de outras sociedades científicas na área. Vale destacar o código de 2013 da Sociedade Brasileira de Computação, cuja Comissão de Ética data da mesma época. O código atual da ACM, aprovado em 2018, tem uma cláusula que reflete a preocupação contemporânea com práticas responsáveis no uso (e coleta) de dados, e na criação de algoritmos e programas – “[...] 3.7 Reconheça e atente especialmente para sistemas que sejam integrados à infraestrutura da sociedade” (ACM Committee on Professional Ethics, 2018).

Os termos “ética no uso de dados” (*data ethics*) e “ética dos algoritmos” são em geral tratados em dois momentos. O primeiro estuda as atividades associadas ao ciclo de vida dos dados, inclusive com preocupações sobre como evitar introduzir discriminação ou distorções na coleta de dados que induzam a algoritmos e decisões preconceituosas – como as mencionadas na seção anterior. Já a ética na especificação e implementação de algoritmos se refere a questões que, quando da execução dos algoritmos, produzam discriminação, causem danos físicos ou morais, invadam a privacidade das pessoas, propaguem notícias falsas (*fake news*), dentre outros. Essas questões estão na origem de disciplinas de pós-graduação específicas e de centros de pesquisa dedicados ao estudo dessas questões, sempre envolvendo colaboração de filósofos, humanistas e cientistas da computação, como no Big Data Institute (2017) da Universidade de Oxford.

A Computação pode evidenciar e trazer para o primeiro plano problemas sociais e políticos decorrentes da digitalização da sociedade.

Como visto neste capítulo, a fronteira entre dados e algoritmos está cada vez mais tênue, principalmente em IA, em que os dados induzem os modelos, que irão produzir mais dados. A ética associada a dados e algoritmos (O’Neil, 2016), combinada com a popularização recente dos algoritmos de Aprendizado de Máquina, vem aumentando a preocupação com os modelos gerados por IA, que originou uma área de pesquisa denominada “inteligência artificial responsável”.

A IA responsável cobre tanto os aspectos que devem ser observados durante o ciclo de vida dos dados, quanto os próprios modelos, que devem ser éticos e justos, não embutir qualquer forma de preconceito e ser transparentes. Em várias situações, muitos dos comportamentos irresponsáveis, ou antiéticos, dos modelos se devem a padrões existentes no conjunto de dados utilizados para gerá-los. Para que a IA tenha um impacto positivo na nossa vida, ela deve seguir premissas que guiem o seu uso nesta direção. Isto se reflete nas recomendações da UNESCO sobre a ética em IA, aprovadas em novembro de 2021 (United Nations Educational, Scientific and Cultural Organization, 2021).

Os benefícios dos sistemas algorítmicos são múltiplos, como visto ao longo deste capítulo. Entretanto, dada a acelerada expansão de serviços operados por algoritmos, há uma crescente preocupação na sociedade com a adoção de algoritmos em áreas sensíveis, como serviços de saúde (Muller et al., 2021), policiamento preditivo, identificação facial, concessão de benefícios sociais, dentre outros. Dado que o avanço da digitalização não tem retorno, é importante criar mecanismos para prevenir as consequências adversas dos sistemas algorítmicos. Tais mecanismos passam por políticas públicas e pela regulamentação de sistemas algorítmicos, em especial os sistemas de IA. A Computação tem um papel fundamental nesses novos tempos de sociedades digitalizadas. A pesquisa e o desenvolvimento da Computação serão chave para criar conhecimento e tecnologias que permitam aumentar a trans-

parência e a responsabilização dos processos algorítmicos, contribuindo para criar serviços mais justos, menos discriminatórios e mais confiáveis.

A FAPESP E O FINANCIAMENTO À PESQUISA, DESENVOLVIMENTO E INOVAÇÃO EM COMPUTAÇÃO

A FAPESP há décadas vem financiando pesquisas em todos os ramos da Computação. O fascículo 3 da série FAPESP 60 anos (Fundação de Amparo à Pesquisa do Estado de São Paulo, 2022) tem uma extensa apresentação de vários desses avanços. Foi pioneira no apoio à criação de infraestrutura computacional – por exemplo, financiando um dos primeiros computadores instalados em universidades brasileiras no início dos anos 1960, ou seu papel desde 1988 na criação e consolidação da internet no Brasil, dentre muitos outros.

Da mesma forma, financiou e continua financiando projetos inovadores, centros de pesquisa centrados em IA ou dedicados à Engenharia e Ciência Computacional. O programa em eScience e Data Science, criado em 2013, é uma das iniciativas que reconhece a ubiquidade da pesquisa em Computação em praticamente todos os outros domínios do conhecimento. Para dados, destaca-se a criação em 2020 de um dos maiores repositórios de dados abertos sobre covid da América do Sul, o “COVID-19 DataSharing/BR”, cujos dados são acessados por dezenas de países em milhares de downloads, gerando trabalhos de pesquisa mas também ajudando o desenvolvimento de produtos que o usam para treinar algoritmos de IA. A seguir destacamos alguns aspectos do apoio FAPESP associados às aplicações tratadas na seção sobre Algoritmos, que trata de pesquisas em IA e em Bioinformática.

Assim como a Bioinformática deslanchou no mundo por causa de projetos de sequenciamento de genomas, o mesmo ocorreu no Brasil (Setubal, 2004), graças à FAPESP. Um destes projetos que foi vital para criar uma infraestrutura computacional sofisticada e realizar análises comple-

puting are key to creating knowledge and technologies that allow increased transparency and assess the responsibility of algorithmic processes, thereby contributing to create more equitable, less discriminatory and more reliable services.

FAPESP AND THE FUNDING OF RESEARCH, DEVELOPMENT AND INNOVATION IN COMPUTING

For decades, FAPESP has been financing research in all areas of Computing. Volume 3 of the FAPESP 60 years series (Fundação de Amparo à Pesquisa do Estado de São Paulo, 2022) has an extensive presentation of several such advances. Among many other initiatives, it was a pioneer in supporting the creation of computational infrastructure in the country – for instance, funding one of the first computers installed in a Brazilian university at the beginning of the 1960s, or its role, since 1988, in creating and consolidating the internet in Brazil.

Similarly, it funded and continues to fund innovative projects, as well as research centers focusing on AI or dedicated to Computational Science and Engineering. Its eScience and Data Science program, created in 2013, is one of the initiatives that recognizes the importance of Computing research in virtually all domains of knowledge. Regarding data, it is worthwhile mentioning the creation of one of the largest COVID-related open data repositories in South America, “COVID-19 DataSharing/BR” – whose data are accessed by tens of countries in thousands of downloads, not only for research, but also helping to develop products that are used to train AI algorithms. We will now highlight some aspects of FAPESP’s support associated with applications considered in the section on Algorithms, for AI and Bioinformatics.

Just as Bioinformatics research expanded throughout the world due to genome sequencing projects, the same occurred in Brazil (Setubal, 2004), thanks to FAPESP. One of the research projects that was vital to the creation of a sophisticated computational infrastructure and complex analyses was the genome project for bacteria *Xylella fastidiosa*, that was conducted between 1997 and 2000. Other projects that helped to sequence the genome for the parasite *Schistosoma mansoni*, or that sequenced cancer samples, were also important to create Bioinformatics groups in Brazil. Many of these groups were part of a virtual genomics institute created by FAPESP named Organization for Nucleotide Sequencing and Analysis (ONSA). The ONSA² acronym was coined as a word play with the acronym of the Institute for Genomic Research (TI-

² ONSA phonetically reproduces the word for ‘jaguar’ in Portuguese (onça – a native animal of the *Panthera* genus) just as ‘TIGR’ is similar to ‘tiger’ (another animal of genus *Panthera*).

GR) founded in 1992 to sequence various genomes, including the human genome. Since then, several Bioinformatics laboratories sprang up in Brazil, as well as graduate programs focused on this research field. There is even a Brazilian Association for Bioinformatics and Computational Biology (AC3C) whose aim is to promote teaching and research in these areas, with courses and scientific events.

FAPESP has also given significant support to Brazilian AI research, particularly through financing Brazilian research centers, such as the joint FAPESP-IBM call for proposals at the beginning of 2019, which selected the C4AI (Center for Artificial Intelligence) center. The call at the end of the same year jointly with the MCTI Ministry and CGI.br (the Brazilian Internet Steering Committee) also provided funding for up to eight centers of applied AI research to investigate problems in areas such as Health, Agriculture, Industry and Smart Cities; in this latter call, four centers were selected, covering a variety of these topics in different combinations. In 2021, another call was announced, to fund two additional AI centers, considering topics related to information and cybersecurity, and AI in the broader sense. The variety of topics covered by the selected centers shows the growing importance of AI in a wide range of domains of knowledge and the recognition of the phenomenon by FAPESP.

REFERÊNCIAS/REFERENCES

Abebe, R., Barocas, S., Kleinberg, J., Levy, K., Raghavan, M., & Robinson, D. G. (2020). Roles for computing in social change. In Association for Computing Machinery (Ed.), *Conference on Fairness, Accountability, and Transparency (FAT*’20)* (pp. 1-9). Association for Computing Machinery. <https://arxiv.org/pdf/1912.04883.pdf>.

ACM Committee on Professional Ethics. (1992). *1992 ACM Code of Ethics and Professional Conduct*. <https://ethics.acm.org/code-of-ethics/previous-versions/1992-acm-code/>.

ACM Committee on Professional Ethics. (2018). *ACM Code of Ethics and Professional Conduct*. <https://ethics.acm.org/>.

Big Data Institute. (2017). <https://www.bdi.ox.ac.uk/study/cdt/ethics>.

Duarte, N. (2017). *Automated “extreme vetting” won’t work and will be discriminatory*. Center for Democracy & Technology. <https://cdt.org/insights/automated-extreme-vetting-wont-work-and-will-be-discriminatory/>.

Figueira, J., Greco, S., & Ehrogott, M. (2005). *Multiple criteria decision analysis: state of the art surveys*. (Springer’s International Series). Springer-Verlag.

xas foi o projeto genoma da bactéria *Xylella fastidiosa*, realizado entre os anos de 1997 e 2000. Outros projetos que ajudaram a sequenciar o genoma do parasita *Schistosoma mansoni* ou que sequenciaram amostras de câncer também foram importantes para criar grupos especializados em Bioinformática no Brasil. Muitos desses grupos fizeram parte de um instituto virtual de genômica criado pela FAPESP e denominado Rede ONSA (Organização para Sequenciamento e Análise de Nucleotídeos, na sigla em inglês). ONSA inclusive brincava com a sigla do *Institute for Genomic Research* (TIGR) fundado em 1992 para o sequenciamento de diversos genomas, incluindo o humano. Desde então, vários laboratórios de Bioinformática surgiram no Brasil, assim como diversos programas de pós-graduação voltados para esta área. Existe até uma Associação Brasileira de Bioinformática e Biologia Computacional (AB3C), cujo objetivo é promover o ensino e a pesquisa de Bioinformática e Biologia Computacional, com cursos e eventos científicos.

Fry, C. (1985). Structure and interpretation of computer programs. *Computer Music Journal*, 9(3), 81-84.

Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP. (2022). Pioneirismo digital. In *FAPESP 60 anos – Ciência, Cultura e Desenvolvimento* (Vol. 3). FAPESP. <https://60anos.fapesp.br/livro/>.

International Telecommunication Union. (2014). Smart sustainable cities: An analysis of definitions United Nations (Focus Group Technical Report). International Telecommunication Union (ITU-T), Focus Group on Smart Sustainable Cities (FG-SSC).

Knuth, D. (1998). *The Art of Computer Programming* (3 vol.), Addison-Wesley.

Korinek, A., & Stiglitz, J. (2021). *Artificial intelligence, globalization, and strategies for economic development* (Working Paper 28453). National Bureau of Economic Research. <http://www.nber.org/papers/w28453>.

Kostka, G. (2019). *China’s social credit systems and public opinion: explaining high levels of approval*. *New Media & Society*, 21(7), 1565-1593. <https://journals.sagepub.com/doi/full/10.1177/1461444819826402>.

A FAPESP também tem prestado um grande apoio às pesquisas brasileiras em IA, particularmente no financiamento a centros brasileiros de pesquisa, por exemplo, por meio da chamada de propostas no início de 2019, junto com a IBM, que selecionou a proposta do C4AI (Centro de Inteligência Artificial). Destaca-se também a chamada, no final do mesmo ano, para financiamento, junto com o MCTI e o CGI.br (Comitê Gestor da Internet no Brasil), de até oito centros de pesquisa aplicada em IA nos temas Saúde, Agricultura, Indústria e Cidades Inteligentes, sendo selecionados quatro centros cobrindo uma variedade desses temas, em diferentes combinações. Em 2021, foi lançada a segunda chamada, para o financiamento de dois centros, nos temas Segurança da Informação e Segurança Cibernética e IA em sentido amplo. A variedade de temas dos centros selecionados mostra a presença crescente da IA nos mais variados domínios do conhecimento e o reconhecimento que a FAPESP tem do fenômeno.

Laney, D. (2001). *3D data management: controlling data volume, velocity and variety*. META Group Research Note. <https://www.bibsonomy.org/bibtex/742811cb00b303261f79a98e9b80bf49>.

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth summer research project on artificial intelligence. *AI Magazine*, 27(4), 12-14. <http://dx.doi.org/10.1609/aimag.v27i4.1904>.

Ministério da Ciência, Tecnologia e Inovações. (2021). A plataforma. <https://cidadesinteligentes.hmg.apps.kloud.rnp.br/sobre>.

Moore, G. (1965). Cramming more components onto integrated circuits. *Electronics*, 38(8), pp 114 ff. <https://ieeexplore.ieee.org/document/4785860>.

Muller, H., Mayrhofer, M. T., Van Veen, E. B., & Holzinger, A. (2021). The ten commandments of ethical medical AI. *Computer*, 54(7), 119-123.

O’Neil, C. (2016). *Weapons of math destruction: how big data increases inequality and threatens democracy*. Penguin.

Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm

- used to manage the health of populations. *Science*, 366(6464), 447-453.
- Resende, G., Melo, P., Sousa, H., Messias, J., Vanconcelos, M., Almeida, J. M., & Benevenuto, F. (2019). (Mis)Information dissemination in whatsapp: Gathering, analyzing and countermeasures. In *The World Wide Web Conference, WWW '19* (pp. 818-828). Association for Computing Machinery.
- Rjab, A. B., & Mellouli, S. (2019). Artificial intelligence in smart cities: Systematic literature network analysis. In *Proceedings of the 12th International Conference on Theory and Practice of Electronic Governance, ICEGOV 2019* (pp. 259-269). Association for Computing Machinery.
- Roy, B. (1985). *Méthodologie multicritère d'aide à la décision*. Economica.
- Sachs, J. D., Schmidt-Traub, G., Mazzucato, M., Messner, D., Nakicenovic, N., & Rockström, J. (2019). Six Transformations to achieve the Sustainable Development Goals. *Nature Sustain*, 2, 805-814. <http://dx.doi.org/10.1038/s41893-019-0352-9>.
- Setubal, J. C. (2004). Bioinformática. In L. Mir (Ed.), *Genômica* (pp. 105-118). Editora Atheneu.
- Suchman, L., Blomberg, J., Orr, J., & Trigg, R. (1999). Reconstructing technologies as social practice. *The American Behavioral Scientist*, 43(3), 392-408.
- Sweeney, L. (2013). Discrimination in Online Ad Delivery: Google ads, black names and white names, racial discrimination, and click advertising. *Queue*, 11(3), 10-29. <http://dx.doi.org/10.1145/2460276.2460278>.
- The Economist. (2017, May). *The world's most valuable resource is no longer oil, but data*. <https://www.economist.com/leaders/2017/05/06/the-world-s-most-valuable-resource-is-no-longer-oil-but-data>.
- Townsend, A. M. (2013). *Smart Cities: Big Data, Civic Hackers, and the Quest for a New Utopia*. W. W. Norton & Company.
- Tribunal Superior Eleitoral. (2020). TSE assina parceria com Facebook Brasil e WhatsApp Inc. para combate à desinformação nas Eleições 2020. <https://www.tse.jus.br/imprensa/noticias-tse/2020/Setembro/tse-assina-parceria-com-facebook-brasil-e-whatsapp-inc-para-combate-a-desinformacao-nas-eleicoes-2020>.
- United Nations Educational, Scientific and Cultural Organization – UNESCO. (2021). Recommendation on the ethics of artificial intelligence. In *General Conference* (pp. 1-30). UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000378931?posInSet=25&queryId=f4082765-2f1f-4710-a706-047db14472d1-draft-data-297>.
- United Nations. (2021). *Secretary-General's remarks to Member States on Priorities for 2021*. <https://www.un.org/sg/en/content/sg/statement/2021-01-28/secretary-generals-remarks-member-states-priorities-for-2021-bilingual-delivered-scroll-down-for-all-english-version>.
- Van Regenmortel, M. H. V. (2004). Reductionism and complexity in molecular biology. Scientists now have the tools to unravel biological and overcome the limitations of reductionism. *EMBO Reports*, 5(11), 1016-1020. <https://doi.org/10.1038/sj.embor.740028>.