
DESENVOLVIMENTO DE PROJETOS DE DATA SCIENCE

Gilberto Lourenço Fernandes

iNuTech¹, CV Lattes <http://lattes.cnpq.br/0866467638692010>, gilberto.fernandes@inutech.org.br;

Resumo: A partir da identificação e análise das características técnicas inerentes à projetos de inovação em Ciência de Dados e Inteligência Artificial, esse artigo examina os conceitos fundamentais, metodologias, procedimentos e desafios para a sua execução.

Palavras-chave: Inovação, Ciência de Dados, Inteligência Artificial, Metodologias.

Abstract: Based on the identification and analysis of the technical characteristics inherent to Data Science and Artificial Intelligence projects, this article examines the fundamental concepts, methodologies, procedures and challenges for its execution.

Key words: Innovation, Data Science, Artificial Intelligence, Methodologies.

1. Introdução

No presente momento, de início da Quarta Revolução Industrial e da criação de um admirável mundo novo, enfrentamos um mundo marcado pela convergência de tecnologias e pela forte transformação digital, com redes de internet 5G com capacidade para trafegar cerca de 1.000 vezes mais dados do que a atual rede 4G, Web 3.0, combinando recursos de Realidade Virtual, Realidade Aumentada e IoT, veículos autônomos, blockchain, aplicações de Inteligência Artificial nas mais diversas áreas de atividades humanas, biotecnologia e criptomoedas. Um mundo no qual grandes corporações e governos terão mais dados e conhecimento sobre cada indivíduo, suas preferências e forma de pensar, do que eles próprios. Um mundo automatizado e operado por tecnologias que avançam mais rápido do que as pessoas conseguem se adaptar e se preparar para elas.

A História nos ensina que, por todo o percurso evolutivo humano, vantagens tecnológicas podem representar a distância entre o protagonismo e o papel de coadjuvante. Desse modo, torna-se imprescindível modernizar o ensino, instituições privadas e a Administração Pública, elevando a sua eficiência e capacidade para enfrentar os desafios do século XXI. Da mesma forma como as empresas concebidas sob paradigmas do século XX terão sérias dificuldades para sobreviverem no século

¹ iNuTech, Instituto NuTech de Pesquisa Aplicada em Ciência, Tecnologia e Inovação.
www.inutech.org.br.

XXI se continuarem a atuar como sempre o fizeram, também os serviços públicos precisam se reinventar para atender as necessidades atuais do país e expectativas do cidadão.

São inúmeras as oportunidades atuais de aplicação da Inteligência Artificial e do uso da Ciência de Dados para resolver os mais diversos problemas, sejam no âmbito privado ou público, tornando possível níveis inéditos de eficiência, de benefícios significativos e economia considerável. Entretanto, soluções notadamente inovadoras e aplicadas à problemas específicos, em geral, não estão disponíveis como produtos de mercado, exigindo o desenvolvimento sob demanda, com etapas iniciais de pesquisa básica e/ou aplicada.

Considerando-se os impactos potenciais de uma tecnologia pervasiva, que deverá estar presente em praticamente todas as áreas de atividades humanas, deixa de ser suficiente apenas dominar ferramentas e linguagens de programação, conhecer as técnicas mais apropriadas para cada tipo de solução e utilizar as metodologias mais bem conceituadas. Todos esses itens são absolutamente necessários, mas não são suficientes para evitar os transtornos e prejuízos dos inúmeros casos de insucesso e de comportamento inapropriado de projetos de Ciência de Dados e de aplicações de Inteligência Artificial divulgados nos últimos anos. Há a necessidade de formação multidisciplinar, forte embasamento em fundamentos e equipes com diferentes perfis profissionais.

No caso de aplicações transacionais, as causas de falhas e respectivos prejuízos são bem conhecidos e quantificados, porém as falhas de aplicações de inteligência artificial têm o potencial de acarretar consequências e prejuízos ainda não bem estimados, mas certamente de maiores dimensões.

Vários têm sido os alertas de renomados cientistas e empresários sobre os riscos de aplicações de IA. E, não se trata da possibilidade de robôs dominarem o mundo, terem consciência ou serem capazes de criar ou alterar os seus próprios algoritmos. Tal, possibilidade, inviável pelos atuais modelos de arquitetura computacionais e por todo o corpo de conhecimento da matemática, tem realidade apenas nos roteiros de filmes de ficção científica. Os reais perigos residem em comportamentos inapropriados, deliberados ou acidentais, provocados pelo próprio ser humano, na concepção de tais aplicações.

Negligenciar os cuidados necessários para o desenvolvimento de aplicações de IA, como por exemplo não aplicar as metodologias e técnicas apropriadas, utilizar profissionais sem a devida formação, focar o desenvolvimento de soluções no uso de ferramentas específicas e não nos problemas a serem resolvidos, utilizar algoritmos sem o completo entendimento de seu funcionamento, não tratar apropriadamente os ativos de dados, significa incorrer em riscos difíceis de serem calculados ou antecipados. Agir desse modo é como abrir uma Caixa de Pandora, sem que se tenha ideia do seu conteúdo.

O objetivo do presente trabalho é fornecer uma visão do caminho a ser percorrido para se alcançar o domínio de tais soluções, minimizando e mitigando os riscos e maximizando as chances de sucesso.

2. Sobre as disciplinas de Ciência de Dados e Inteligência Artificial

Atualmente, o termo Ciência da Dados apresenta forte polissemia, devido, principalmente, ao fato de ser um campo amplo e multidisciplinar, abrangendo diversas disciplinas como Ciência da Computação, Ciência da Informação, Ciências Cognitivas, além de áreas da Matemática, como lógica, estatística e análise de redes complexas, entre outras.

A Ciência de Dados, ao tornar-se a sustentação de uma tecnologia pervasiva, tornou-se também um termo amplamente empregado, por vezes de forma equivocada, reduzindo o seu significado ao simples uso de ferramentas de BI (*Business Intelligence*), de BA (*Business Analytics*) ou de ETL (Extração, transformação e Carga de dados). Naturalmente, o emprego desses tipos de ferramentas é característico de Projetos de Ciência de Dados, porém o campo da Ciência de Dados é conceitualmente mais amplo.

Quanto à Inteligência Artificial, tornou-se um termo também difuso, que engloba sob esse significado vários tipos de aplicações, de tecnologias e de técnicas de trabalho. As primeiras referências à Inteligência Artificial remetem à Conferência que definiu a área em 1956, no Dartmouth College, em New Hampshire, realizada como resultado de proposta elaborada em agosto do ano anterior por grandes nomes da época como Marvin Minsky (1927-2016) e Claude Shannon (1916-2001). Em seus primórdios, a Inteligência Artificial seguiu por dois caminhos distintos – os Sistemas Especialistas, baseados em heurísticas, e as Redes Neurais Artificiais.

Como exemplos de aplicações de Inteligência Artificial, podemos citar a detecção, reconhecimento e classificação sons e vozes, imagens e vídeos, detecção e localização de objetos, identificação e reconhecimento de faces e pessoas, análise de sentimentos e reconhecimento de emoções, geração de conteúdo, processamento de linguagem natural, compreendendo nesse caso o reconhecimento ótico de caracteres e de escrita à mão, interpretação linguística, tradução de idiomas, conversão da fala em texto e vice-versa. Quase todos os exemplos acima podem ser classificados como reconhecimento de padrões, uma das principais aplicações de IA.

As aplicações de Inteligência Artificial podem ser supervisionadas, atuando em conjunto com o ser humano, ou não supervisionadas, atuando de modo autônomo. Quanto às tecnologias e técnicas empregadas em projetos de Ciência de Dados e de Inteligência Artificial, temos alguns exemplos como Big Data, Data Analytics, Análise de Redes Semânticas e de Similaridade Textual, Análise de Redes Complexas, Aprendizado de Máquina, incluindo nesse caso as técnicas de *Machine Learning* e *Deep Learning*, além de diversas técnicas para a construção, seleção e escolha de modelos matemáticos e algoritmos.

Por uma perspectiva de maturidade tecnológica, Projetos de Ciência de Dados são em sua essência projetos de inovação. Possuindo características específicas e necessidades próprias dos projetos de PD&I, que os distinguem de outros projetos mais tradicionais da área de Tecnologia da Informação, tanto de sistemas transacionais como também de projetos de *Business Intelligence*, os projetos de Ciência de Dados requerem metodologias de desenvolvimento e metodologias de gestão de projetos próprias para a sua execução.

De forma simplificada, podemos definir os sistemas transacionais e as aplicações de Business Intelligence, como sendo centrados na utilização de bases de dados estruturadas e na análise gaussiana de séries históricas de dados, com o objetivo de fornecimento de informações estatísticas, sob comportamentos diversos em períodos anteriores, e também probabilísticas, para a previsão de comportamentos futuros, porém em ambos os casos suportadas pelo conceito de distribuição normal. Já as aplicações de Ciência de Dados, podem fazer análises preditivas, suportadas pela identificação de padrões e correlações de atributos e apoiadas por técnicas de aprendizado de máquina e análise de redes complexas,

entre outras, e implementadas por algoritmos especializados e previamente calibrados, a partir de dados estruturados e não estruturados.

Diferentemente de projetos tradicionais de desenvolvimento de software, nos quais define-se previamente um conjunto de requisitos que permitem estimar escopo, esforço, prazo e custo antes de seu início efetivo, projetos de Ciência de Dados e de Inteligência Artificial, enquadrados como projetos de inovação tecnológica, possuem incertezas inerentes à sua natureza, que dificultam ou impossibilitam realizar tais estimativas previamente.

O sucesso de projetos tecnológicos é em grande parte determinado pelo planejamento de sua execução, incluindo definições de escopo e de resultados esperados, além de estimativas iniciais de esforço, custo e prazo. Entretanto, em projetos de Pesquisa, Desenvolvimento e Inovação (PD&I), a tentativa de determinação prévia de tais variáveis torna-se incompatível com a natureza metodológico-experimental desse tipo de projeto, introduzindo-se assim o conceito de risco tecnológico.

Riscos e incertezas são inerentes à atividade de PD&I, na qual hipóteses ou linhas de trabalho podem se revelar, ao longo de seu desenvolvimento, como caminhos inapropriados, resultando na busca por novas alternativas. Tal situação, absolutamente normal em projetos de PD&I, acarreta sérias dificuldades de previsibilidade, sejam de escopo, esforço, prazo ou custo, exigindo desse modo a formulação de planejamento de execução próprio a esse tipo de projeto.

Desse modo, reduzir os riscos tecnológicos de projetos de inovação torna-se fator de suma importância para a sua viabilidade e sucesso.

3. Sobre Metodologias para Projetos de Ciência de Dados

Uma das formas mais efetivas de redução de riscos em projetos de PD&I é a utilização de metodologias de referência apropriadas. Em função da crescente demanda por projetos de Ciência de Dados, e com o objetivo de atender à natureza própria desses projetos, surgiram nas últimas duas décadas vários processos e metodologias, semelhantes em essência, porém com diferentes enfoques, conhecidos de forma geral como *Knowledge Discovery and Data Mining process models* (Modelos de processos de descoberta de conhecimento e mineração de dados), ou

simplesmente KDDM. Estas metodologias e processos têm em comum o objetivo padronizar e conferir maior rigor às tarefas de identificação, qualificação, extração, tratamento, modelagem e avaliação de conjuntos de dados.

As metodologias de referência mais utilizadas para o desenvolvimento de projetos de Ciência de Dados, segundo pesquisa do KDnuggets, conceituado site especializado em Ciência de Dados, são apresentadas a seguir na figura 1.² Dentre as metodologias relacionadas, a mais utilizada globalmente para projetos de Ciência de Dados é o CRISP-DM (*Cross-Industry Standard Process for Data Mining*), a qual o presente trabalho tomará como referência. Em comum, tais metodologias preveem fases e ciclos iterativos, com número imprevisível de iterações no início de cada projeto, tornando explícitas as dificuldades de estimativas prévias de esforço ou prazo de execução.

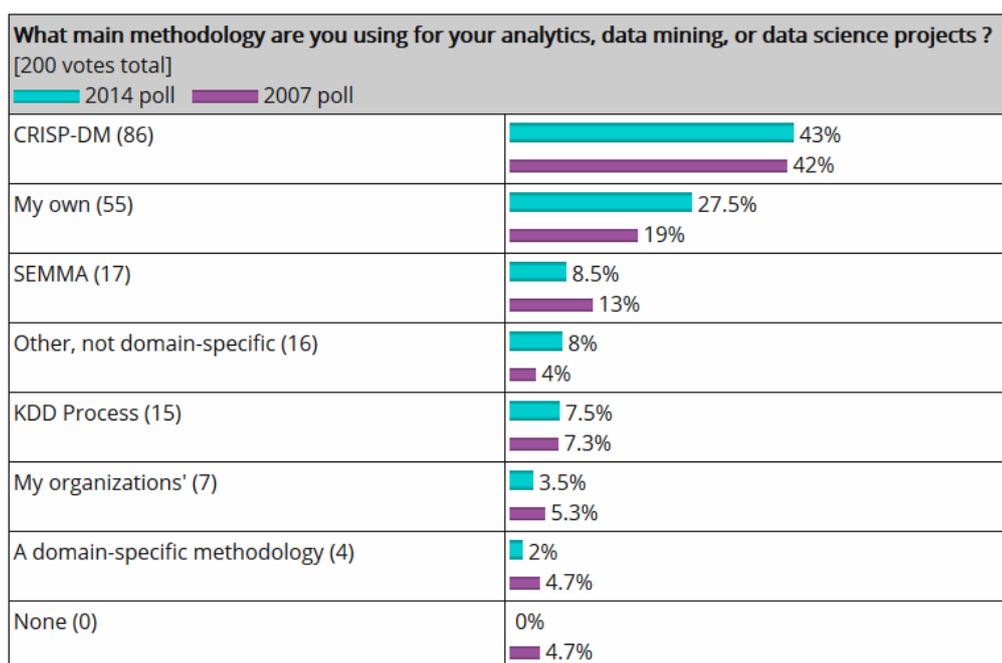


Fig. 1. Metodologias mais utilizadas para projetos de Ciência de Dados

Fonte: <https://www.kdnuggets.com/2014/10/crisp-dm-top-methodology-analytics-data-mining-data-science-projects.html>

O CRISP-DM foi desenvolvido por um consórcio internacional de organizações interessadas em projetos de Ciência de Dados, formado em 1996.³ A primeira versão da metodologia, o CRISP-DM 1.0, foi publicada em março de 1999, tendo por missão

² Distribuição por região dos votos da pesquisa: EUA/Canadá, 45.5%; Europa, 28.5%; Ásia, 14%; América Latina, 9.5%; Outros, 2.5%.

³ NCR Systems Engineering Copenhagen (EUA e Dinamarca), DaimlerChrysler AG (Alemanha), SPSS Inc. (EUA), e OHRA Verzekeringen e Bank Groep B.V. (Holanda).

atender a qualquer tipo de entidade geradora ou consumidora de grandes volumes de informação.

Reunindo as melhores técnicas e práticas desenvolvidas pelo mercado, o CRISP-DM é uma metodologia aberta, não-proprietária, gratuita e capaz de integrar os diferentes contextos e perfis profissionais que a Ciência de Dados envolve. Voltada a aprimorar a qualidade dos processos de coleta, modelagem e análise de dados, esse conjunto de práticas reduz efetivamente os riscos inerentes aos projetos de inovação.

Entre 2006 e 2008 houve um esforço de atualização da metodologia pelo consórcio responsável, com a intenção de gerar a versão CRISP-DM 2.0. Entretanto, são desconhecidos os resultados dessa iniciativa. Atualmente, expressões modernas dessa prática são empregadas nos temas mais relevantes da Ciência dos Dados, como *BigData*, *Analytics*, *Machine Learning*, *Deep Learning*, entre outras. A figura 2 apresenta o CRISP-DM, definido como um percurso metodológico que reúne técnicas e táticas organizadas em um esquema cíclico de seis fases e uma ordem definida.

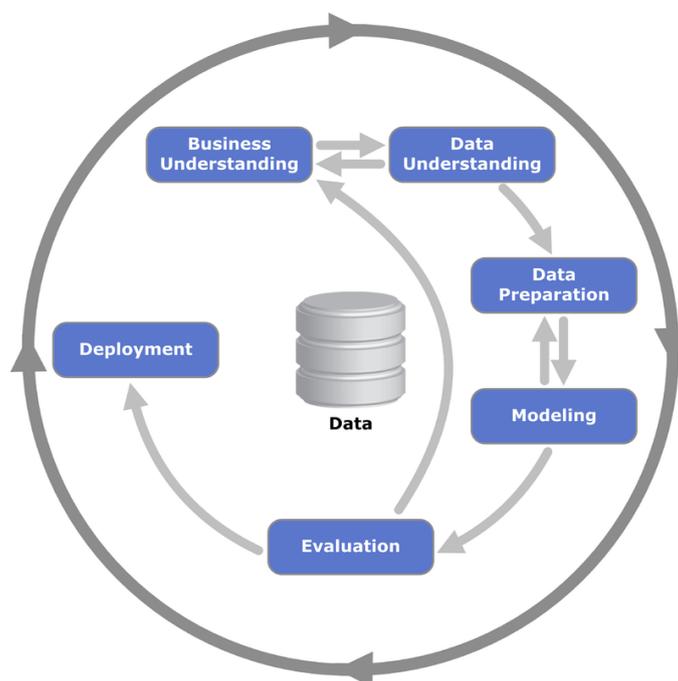


Fig. 2. Fases do Modelo de Referência do CRISP-DM
Fonte: <https://www.the-modeling-agency.com/crisp-dm.pdf>

Diferentemente de processos iterativos incrementais⁴, amplamente utilizados

⁴ O modelo iterativo incremental é um dos mais tradicionais processos de desenvolvimento de aplicações de software, criado como opção ao modelo de desenvolvimento em cascata. Enquanto o modelo em cascata implementa um processo relativamente linear e sequencial das diversas etapas do desenvolvimento de software, como a elicitación de requisitos, design, codificação e testes, realizando

em desenvolvimento de software, as iterações previstas nas metodologias próprias a projetos de Ciência de Dados, como por exemplo o CRISP-DM, podem não incluir nenhum incremento em relação à iteração anterior, consequência natural de processos experimentais, sendo necessário o retorno ao início da fase e a execução de todas as atividades realizadas anteriormente.

Nesse esquema metodológico, há um roteiro englobando todo o conjunto de práticas, indicando não somente a eventual necessidade de se refazer o percurso metodológico, em função de avaliações ou resultados intermediários insatisfatórios, como também pela necessidade eventual de se dividir e tratar separadamente objetivos múltiplos.

Na metodologia CRISP-DM também são previstos microciclos iterativos, englobando uma ou mais fases. Esse esquema metodológico, contemplando pequenos ciclos iterativos, vem ao encontro de características e necessidades presentes em projetos de Ciência de Dados, como por exemplo o entendimento gradual tanto dos processos de negócio como das amostras de dados examinadas.

O entendimento do negócio, do problema a ser tratado e dos dados disponíveis, atividades desenvolvidas logo nas duas primeiras fases metodológica, podem impactar fortemente a definição de escopo e dos objetivos do projeto. Desse modo, as possibilidades de retorno e benefícios, alternativas e estratégias de execução, somente são passíveis de avaliação e definidas após o início efetivo do projeto, sendo continuamente refinados à medida que se avança no percurso metodológico.

A presença dos microciclos iterativos também se presta à mitigação de riscos, antecipando problemas e reduzindo eventual retrabalho, evitando que o projeto avance para as fases seguintes e somente posteriormente sejam percebidos

geralmente uma única entrega da aplicação completa ao final do processo de desenvolvimento, o modelo iterativo incremental apresenta-se como um processo com características de maior agilidade e flexibilidade, sendo o precursor das metodologias ágeis, como por exemplo o SCRUM. Nos processos de desenvolvimento iterativo incremental, o projeto da aplicação de software é dividido em suas diversas funcionalidades que são desenvolvidas com certo grau de independência, eventualmente em paralelo, em ciclos repetitivos (processo iterativo). Cada ciclo iterativo, no qual são desenvolvidas uma ou mais funcionalidades (processo incremental), assemelha-se a um processo em cascata de curta duração, com a execução das diversas etapas de desenvolvimento de software descritas anteriormente, com uma etapa adicional de integração, que testa o funcionamento da nova funcionalidade em conjunto com o restante da aplicação já desenvolvida. Processos iterativos incrementais permitem a detecção e correção de falhas a cada ciclo iterativo, tornando mais ágil e de menor custo as tarefas de retrabalho.

problemas ou o não atingimento de objetivos e índices de qualidade, que determinem o retorno a fases anteriores, ou até mesmo o seu cancelamento.

Ao final de cada fase ou iteração, deve ser possível definir uma das seguintes sequências para o projeto:

- Os objetivos e índices de qualidade previamente definidos foram alcançados e deve-se avançar para a fase seguinte;
- Os objetivos e índices de qualidade previamente definidos não foram totalmente alcançados, mas existem indícios suficientes para indicar o prosseguimento do projeto. Nesse caso, deve-se repetir o ciclo ou a fase em questão;
- Os objetivos e índices de qualidade não foram alcançados, e existem indícios suficientes para indicar a inviabilidade dos objetivos e o cancelamento do projeto.

4. Sobre Perfis e Competências para Projetos de Ciência de Dados

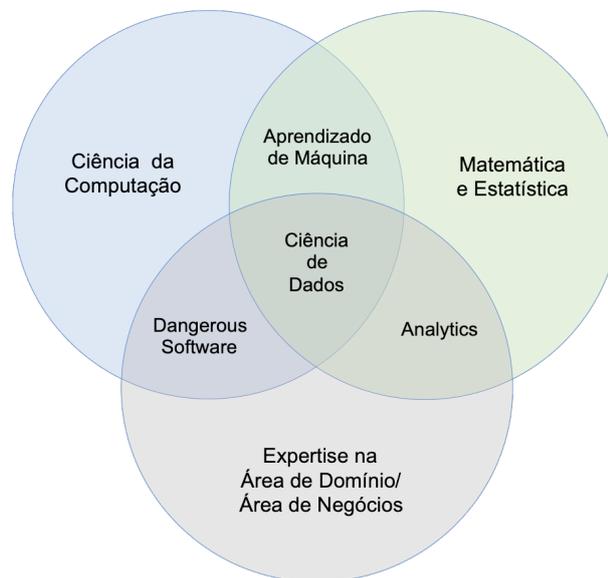
Adicionalmente às características metodológicas exploradas anteriormente, outra questão que deve ser abordada dentro do contexto desse trabalho, são as competências profissionais necessárias para a realização de Projetos de Ciência de Dados.

A Ciência de Dados sendo um campo multidisciplinar, formado pela junção de áreas disciplinares independentes, exige necessariamente diferentes tipos de perfis e competências para o desenvolvimento e a implementação de Projetos de Ciência de Dados, conforme representado na figura 3, a seguir.

Assim, projetos de Ciência de Dados e de IA exigem para o seu desenvolvimento e implementação três perfis profissionais, de áreas distintas, com as competências descritas a seguir, que devem atuar em estreita colaboração:

- Cientista de Dados: pesquisador com profundos conhecimentos e experiência em pesquisa básica e aplicada, e em disciplinas específicas da Matemática, com destaque para a Estatística e Análise de Redes Complexas, e capacidade para selecionar, testar, entender o funcionamento, alterar, criar e calibrar algoritmos;

- Especialistas na área de domínio do negócio: profissionais experientes nos diversos aspectos da área de domínio, sejam de ordem técnica, administrativa, jurídica, comercial ou financeira, analista de negócios e processos;
- Especialistas em Ciência da Computação e Tecnologia da Informação: engenheiro, arquiteto ou analista de dados, responsável pela execução das fases de entendimento e preparação de dados, com a experiência necessária para o trabalho de modelagem da solução, em conjunto com o cientista de dados.



• Figura 3. O que é Ciência de Dados

O entendimento profundo das áreas de atuação e áreas de negócio da instituição, e de seus respectivos processos organizacionais, objetivo da primeira das fases metodológicas para o desenvolvimento de Projetos de Ciência de Dados, serão os insumos para a formulação das perguntas estratégicas que o projeto pretenderá responder. Para a obtenção de resultados relevantes, é necessário que se consiga fazer as perguntas certas. E, para isso, torna-se necessária a participação ativa de especialistas nas áreas de domínio em estudo, com competência para identificar, selecionar e priorizar os problemas a serem tratados.

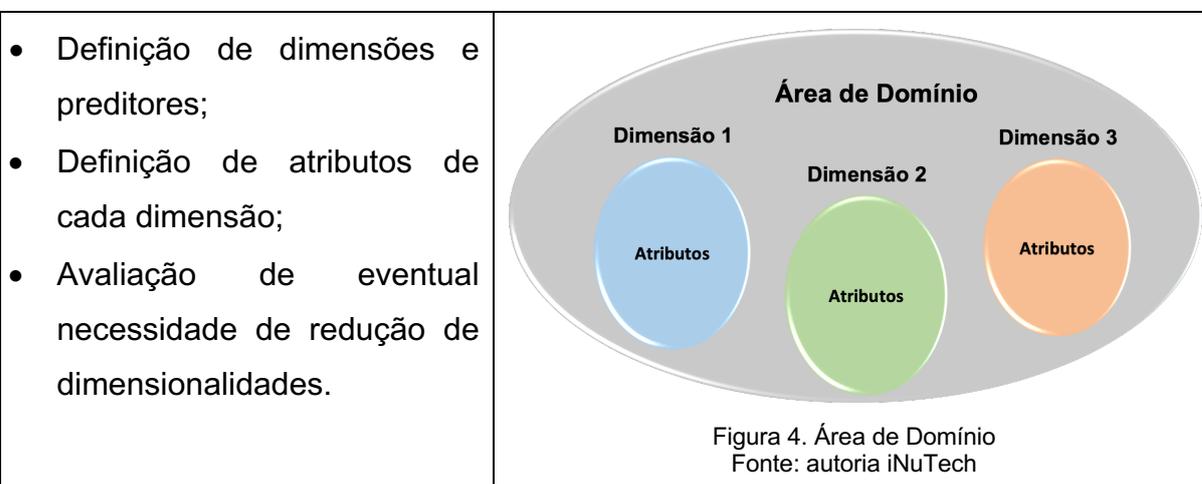
5. Sobre o Percorso Metodológico de Projetos de Ciência de Dados

Uma vez definidas as perguntas de negócio que serão o objeto do projeto, cientistas de dados, em conjunto com os profissionais de TI, atendendo ao percurso

metodológico, deverão transformar essas questões de negócio em perguntas de dados. A correta especificação de dimensões e atributos necessários às respostas das perguntas de dados é determinante para a seleção apropriada de bases e amostras de dados, tarefa essa que pode ser dificultada tanto pelo tamanho e diversidade como pelo expressivo crescimento das bases disponíveis, sejam internas ou externas.

Desse modo, a definição da Área de Domínio do projeto, com suas respectivas dimensões e atributos, é um dos marcos importantes, resultantes da Fase de Entendimento de Dados.

Definição de Área de Domínio:



Após a definição das perguntas de dados, da seleção, aquisição, tratamento e disponibilização de amostras de dados, inicia-se a o trabalho de criação de modelos matemáticos, baseados em diferentes técnicas, de acordo com as características de cada projeto. Nesta fase, são selecionados ou criados, alterados, testados e calibrados os modelos e algoritmos que deverão ser capazes de responder às perguntas de negócio.⁵ A participação de cientistas de dados com a devida competência e experiência é de fundamental importância para a obtenção de modelos matemáticos eficientes, respostas corretas e resultados relevantes.

Uma vez que os modelos matemáticos estejam operacionais, a fase metodológica seguinte, anterior ao envio de requisitos para a construção de aplicações de software, trata da avaliação destes modelos. Nessa fase, novamente

⁵ Um modelo matemático é uma representação da realidade ou interpretação possível de um cenário. Algoritmo é a implementação em código do modelo matemático.

torna-se necessária a participação dos especialistas na área de domínio, para a interpretação dos resultados obtidos e eventuais ajustes e calibrações dos algoritmos.

A dedicação exigida de cada um dos três perfis profissionais sofre variações a medida que se avança nas fases metodológicas dos Projetos de Ciência de Dados. As fases iniciais exigem maior dedicação de cientistas de dados e especialistas nas áreas de domínio e, na medida do progresso do projeto, tal exigência de dedicação vai sendo reduzida, de modo que não há um esforço constante. De modo inverso, o mesmo se passa com o esforço previsto para a implementação e teste de artefatos demandados à equipe de desenvolvimento de aplicações de software. Essa situação está representada na figura 5, a seguir.

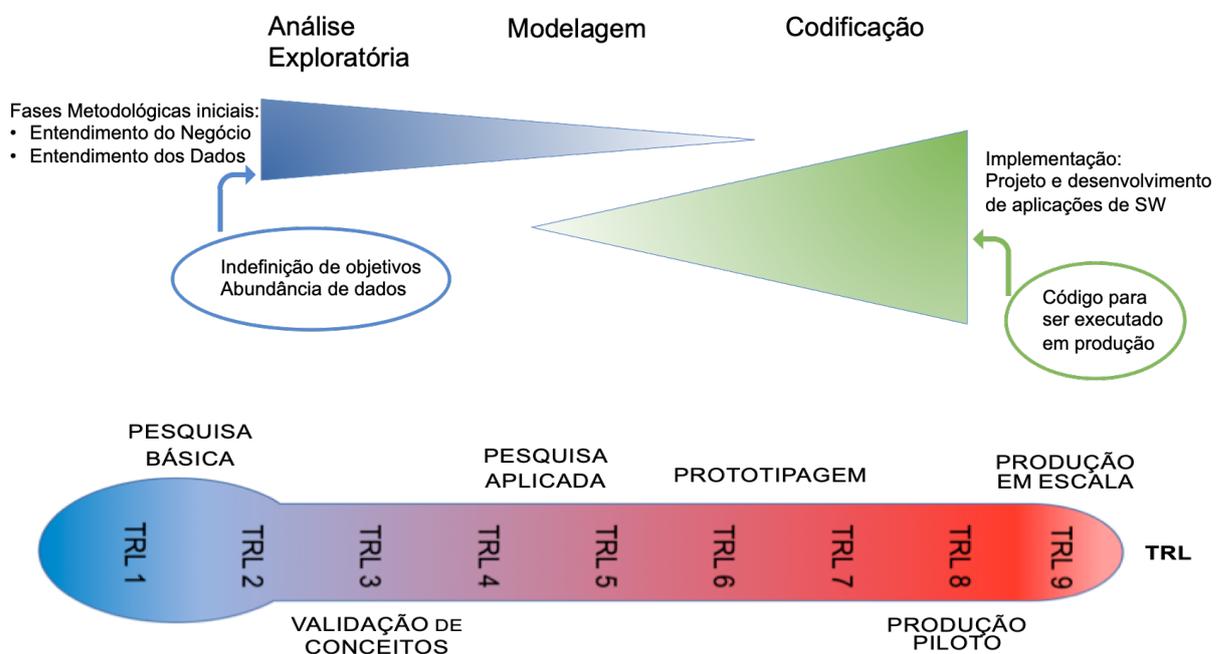


Figura 5. Esforço de Data Science e de desenvolvimento de SW, distribuído pelas fases metodológicas⁶
Fonte: autoria iNuTech

Dada as complexidades envolvidas, é natural e aconselhável que as organizações que resolvam desenvolver projetos de Ciências de Dados busquem apoio externo especializado para atuar em conjunto com os profissionais da própria empresa. O risco de falha de projetos eleva-se significativamente pela ausência de alguma das competências profissionais anteriormente mencionadas e pelo uso indiscriminado de ferramentas e algoritmos, sem uma análise crítica capaz de entender o seu funcionamento e detectar possíveis problemas. Na figura 3, tal

⁶ TRL - Technology Readiness Level. Escala de maturidade tecnológica, desenvolvida pela NASA.

situação é representada pela área de interposição denominada de “*Dangerous Software*”. Desse modo, a escolha de tecnologias, produtos, ferramentas, técnicas e metodologias, por princípio, deve ser agnóstica e baseada unicamente em critérios técnicos definidos pelas especificidades de cada projeto. Tal prática e liberdade de escolha reforçam a mitigação de riscos tecnológicos.

Nesse contexto de complexidade técnica e do potencial disruptivo e de transformação estrutural que análises preditivas permitem, recomenda-se fortemente a internalização de conceitos, metodologias, processos, técnicas e tecnologias relacionadas à Projetos de Ciência de Dados, por equipes internas das instituições que planejem a execução de projetos de Ciência de Dados, ainda que o objetivo seja de terceirizar completamente o seu desenvolvimento.

Em Projetos de Ciência de Dados, recomenda-se ainda, sempre que possível, o uso de produtos, ferramentas e algoritmos com código aberto, que permitam o entendimento de seu funcionamento, evitando-se mecanismos preditivos do tipo “caixa preta”, que elevam os riscos de comportamentos inadequados, sem que seja possível investigá-los, dificultando a sua detecção e correção.

Mecanismos preditivos do tipo “caixa preta” nem sempre são o resultado do uso de produtos, ferramentas e algoritmos proprietários ou sem a devida transparência de seu código. Eventualmente, as características do problema a ser resolvido favorece a utilização de técnicas e tecnologias específicas, como por exemplo *machine learning* que, embora possa ser baseada em algoritmos de código aberto, pode tornar inviável o entendimento de seu funcionamento e a forma como chega aos resultados apresentados. Desse modo, dependendo das implicações das decisões a serem tomadas apoiadas pelas aplicações de Inteligência Artificial, desaconselha-se a utilização de produtos, técnicas ou tecnologias que resultem em mecanismos do tipo “caixa preta”.

A internalização de conhecimentos, aliada ao uso de algoritmos de código aberto e a realização de auditorias periódicas sobre o funcionamento destes algoritmos, promove significativamente a mitigação de riscos de falhas ou de baixa eficiência. A verificação de eventual incorporação de viés, uma das atividades a ser efetuada regularmente por ocasião das auditorias programadas, permite a detecção

de desvios comportamentais nos algoritmos.⁷ Como os dados utilizados para testar e treinar os algoritmos são em grande parte gerados por seres humanos, implicando na incorporação de vieses eventualmente presentes na geração dos dados, nas análises e interpretações humanas, tal situação deve ser tratada preventivamente, por meio das auditorias periódicas, e com o devido rigor. No Anexo I, encontra-se uma coletânea de casos de insucesso em projetos de IA, ocorridos em 2017 e 2018.

6. Os Limites da Inteligência Artificial

Apesar dos admiráveis avanços tecnológicos, alguns fatores limitam o alcance do que podemos fazer atualmente com as aplicações de IA, principalmente para atingirmos a IA Geral. Tais limitações podem ser categorizadas como:

- Limitações da Máquina de Turing: executa apenas problemas Turing computáveis;
- Questões arquiteturais: arquitetura de von Neumann x arquitetura neuronal;
- Problemas da Lógica e da Matemática: impossibilidade de algoritmização do pensamento humano.

6.1. A Máquina de Turing e a Arquitetura Clássica de Computadores

Nesses quase 80 anos em que o modelo clássico de arquitetura de computadores vem sendo perpetuado, as melhorias sistemáticas em desempenho de processamento e armazenamento de dados, confiabilidade, assim como a equivalente redução em dimensões e custos, atestam suficientemente bem a sua eficiência. No entanto, apesar das inovações extremamente notáveis ocorridas neste período, a arquitetura proposta por Turing e von Neumann tem resistido bravamente a possíveis mudanças de paradigmas, permanecendo praticamente inalterada em sua essência.

A evolução tecnológica computacional tem se concentrado basicamente no aumento da força bruta, mantendo seus limites computacionais inalterados, sendo

⁷ São inúmeros os casos já documentados de viés em aplicações de Inteligência Artificial, nas mais diversas áreas de atividade, como por exemplo a formação de *credit scores* de clientes de instituições financeiras, ou a sugestão de penalidades para condenados por crimes violentos. Um dos casos registrados de maior repercussão de ocorrência de viés na área jurídica é o sistema Compas, utilizado para assessorar juízes do estado norte-americano de Wisconsin sobre a avaliação de periculosidade de presos e risco de reincidência, que tendia a desaconselhar a libertação de negros mais frequentemente que a de brancos. Os algoritmos do Compas analisam 173 atributos, nenhum dos quais sobre raça, e apresentam a probabilidade de reincidência numa escala de 0 a 10.

capaz de computar um conjunto limitado de problemas.

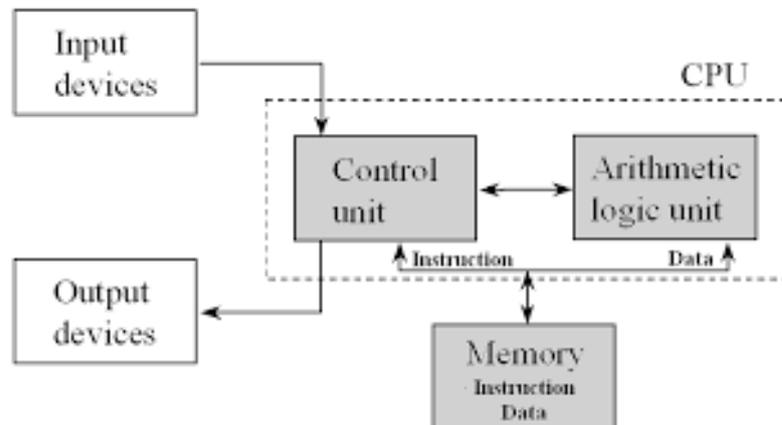


Figura 6. Arquitetura de Turing e von Neumann

- O Problema da Parada, no contexto da teoria da computabilidade, é um problema de decisão que pode ser declarado, da seguinte forma:
 - Dada a descrição de um algoritmo e uma entrada finita, decida se o programa termina de rodar ou se rodará indefinidamente.
- Para Máquinas de Turing, o Problema da Parada é indecidível. A conclusão acima acarreta limitações na área de atuação e nos problemas que podem ser resolvidos pela Máquina de Turing, conhecidos como Problemas Turing Computáveis.

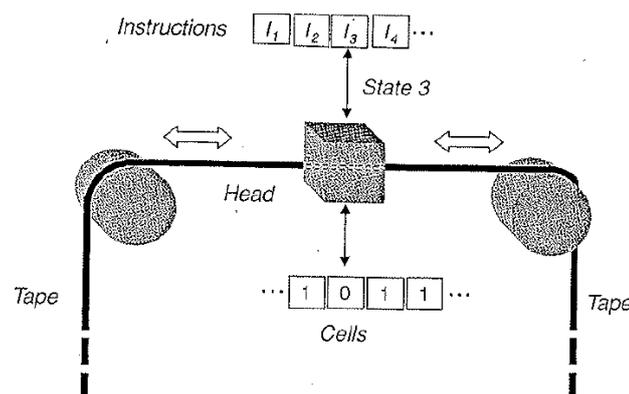


Figura 7. Máquina de Turing

6.2. Arquitetura computacional do cérebro humano

- O cérebro humano possui cerca de 86 bilhões de neurônios;
- Cada neurônio possui em média, entre 5.000 e 10.000 dendritos, possibilitando igual número de conexões com outros neurônios;

- Atuando com base em elevadíssimo número de conexões eletroquímicas, o cérebro humano trabalha de forma maciçamente paralela, a baixa velocidade, com baixo consumo de energia, e capacidade de continuamente alterar e gerar novas conexões;
- Processamento e armazenamento em um mesmo dispositivo (neurônios);
- Redes neuronais atuam com entradas analógicas e saídas digital, o melhor de dois sistemas.

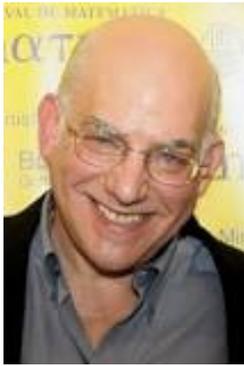
6.3. Paradoxo de Turing e Gödel

Conhecido como Teoremas da Incompletude, esse paradoxo, remonta a dois gigantes da matemática do século 20: Alan Turing e Kurt Gödel.

Na asserção mais conhecida dos Teoremas da Incompletude, um sistema matemático qualquer apresenta uma das seguintes limitações: ou será incompleto (haverá teoremas que são verdade, mas não podem ser provados) ou será inconsistente (haverá contradições, como um teorema que é verdadeiro e falso ao mesmo tempo).

Em função dos Teoremas da Incompletude, alguns problemas computacionais não podem ser resolvidos com algoritmos.

	<p>Kurt Gödel (1906 - 1978), em seus Teoremas da Incompletude, demonstrou que para os sistemas lógicos disponíveis, tais sistemas configuram-se como incompletos ou como inconsistentes.</p>
	<p>Alan Turing (1912 - 1954), provou que em computadores com a arquitetura atual (Máquina de Turing), necessariamente não podem existir algoritmos que sejam capazes de tratar problemas indecidíveis (Problema da Indecibilidade).</p>



Gregory J. Chaitin (1947 -) estendeu os resultados de Gödel e Turing à **Teoria da Informação Algorítmica**.

Resultado dos Teoremas da Incompletude de Gödel:

- Se um sistema é:
 - finito;
 - capaz de expressar a aritmética;
 - recursivo (equivalentemente, Turing-computável);
 - consistente.
- Então o sistema:
 - é incompleto ou
 - não pode provar sua própria consistência.

*“Gödel e Turing responderam às três famosas questões formuladas em 1928 pelo matemático David Hilbert, de forma dramática – e na negativa: **a matemática enquanto estrutura formal não é completa, não é autoconsistente e não é decidível**. Em outras palavras, a mecanização do pensamento humano a partir de uma sequência fixa de regras lógicas é mera fantasia.”*

Marcelo Gleiser em A Ilha do conhecimento, p. 302-303

7. Agradecimentos

Agradecemos as discussões e contribuições dos associados e pesquisadores do iNutech, que inspiraram e participaram na realização do presente trabalho, em especial à Ismael Moura, Jackson Maia e Jörg Bliesener.

8. Referências Bibliográficas

CHAPMAN, Pete; CLINTON, Julian; KERBER, Randy; KHABAZA, Thomas; REINARTZ, Thomas; SHEARER, Colin; WIRTH, Rüdiger (2000). **CRISP-DM 1.0 Step-by-step data mining guides**. Disponível em: <<https://www.the-modeling-agency.com/crisp-dm.pdf>>. Acesso em 17/09/2018.

FERGUSON, Andrew Guthrie. **The Rise of Big Data Policing: Surveillance, Race, and the Future of Law Enforcement**. New York: NYU Press, 2017.

GÓMEZ, Omar Salvador. **Propuesta de mejora sobre la primera etapa del modelo de proceso KDDM, CRISP-DM**. Disponível em:

<https://www.researchgate.net/publication/255621749_Propuesta_de_mejora_sobre_la_primera_etapa_del_modelo_de_proceso_KDDM_CRISP-DM>. Acesso em 17/09/2018.

KDNuggets. **CRISP-DM, still the top methodology for analytics, data mining, or data science projects**. Disponível em: <<https://www.kdnuggets.com/2014/10/crisp-dm-top-methodology-analytics-data-mining-data-science-projects.html>>. Acesso em 17/09/2018.

NUNES, Dierle; MARQUES, Ana Luiza Pinto Coelho. **Inteligência artificial e direito processual: vieses algorítmicos e os riscos de atribuição de função decisória às máquinas**. Revista dos Tribunais on line, vol. 285/2018, p. 421 – 447, 2018. Disponível em: <https://www.academia.edu/37764508/INTELIGÊNCIA_ARTIFICIAL_E_DIREITO_PROCESSUAL_VIESES_ALGORÍTMICOS_E_OS_RISCOS_DE_ATRIBUIÇÃO_DE_FUNÇÃO_DECISÓRIA_ÀS_MÁQUINAS_Artificial_intelligence_and_procedural_law_algorithmic_bias_and_the_risks_of_assignment_of_decision-making_function_to_machines>. Acesso em 09/12/2018.

PMI, Project Management Institute. **PMBOK® Guide – Sixth Edition**. Disponível em: <<https://www.pmi.org/pmbok-guide-standards/foundational/pmbok>>. Acesso em 25/09/2018.

REISMAN, Dillon; SCHULTZ, Jason; CRAWFORD, Kate; WHITTAKER, Meredith. **Algorithmic impact assessments: a practical framework for public agency accountability**. Disponível em: <<https://ainowinstitute.org/aiareport2018.pdf>>. Acesso em 01/12/2018.

RIELAND, Randy. **Artificial Intelligence Is Now Used to Predict Crime. But Is It Biased?** Disponível em: <<https://www.smithsonianmag.com/innovation/artificial-intelligence-is-now-used-predict-crime-is-it-biased-180968337>>. Acesso em 01/12/2018.

SCRUM Org. **The SCRUM Guide**. Disponível em <<https://www.scrumguides.org/index.html>>. Acesso em 25/09/2018.

SRIKANTH T. **Difference of Data Science, Machine Learning**. Disponível em: <<http://www.techexpert.com/difference-data-science-machine-learning/>>. Acesso em 25/09/2018.

McCarthy, J.; Minsky, M. L.; Rochester, N.; Shannon, C. E. **A proposal for the dartmouth summer research project on artificial intelligence (1955)**. Disponível em <<http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>>. Acesso em 15/01/2019.