

A PRACTICAL PROCESS FOR DEPLOYING LOW COST ARTIFICIAL INTELLIGENCE (AI) PROJECTS

Wellington Sousa Aguiar - CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - Orcid: <https://orcid.org/0000-0003-0677-5782>

José Mário Bezerril Fontenelle - CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - Orcid: <https://orcid.org/0000-0001-6828-0123>

José Valclemir Rodrigues Da Silva - CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - Orcid: <https://orcid.org/0000-0003-0830-0203>

Ramiro Francisco Bezerra Dos Santos - CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - Orcid: <https://orcid.org/0000-0002-6352-8756>

The objective of this research was to develop and present a practical and low-cost process for implementing Artificial Intelligence (AI) applications for researchers and small and medium-sized companies based on supervised learning. The study proposes a basic model to enable small businesses to use and become familiar with affordable Artificial Intelligence projects and free-to-use tools. The methodology used in this research was applied research, when the researcher applies their experiences and knowledge in solving real world problems. Bibliographic research was also used through consultation of books, articles, theses and dissertations to give theoretical support to the studies carried out. During the last ten years of research developing this model, we can assess the success in 11 (eleven) completed projects and two in progress. The time of each project ranged from three to six months with accuracy always above 77%. The main result is the process itself in detail. The process with details of its phases using low-cost tools forged over ten years of research is the main academic contribution that has already shown results in real-world applications in research and in small and medium-sized organizations. The defined process allows small and medium companies to use this technology using low-cost tools, generating strategic knowledge hitherto unknown, bringing their strategies closer to large corporations.

Keywords: Process, Information Technology, Artificial Intelligence, Machine Learning, BPMN

UM PROCESSO PRÁTICO PARA IMPLANTAR PROJETOS DE INTELIGÊNCIA ARTIFICIAL (IA) DE BAIXO CUSTO

O objetivo dessa pesquisa foi desenvolver e apresentar um processo prático e de baixo custo para implantação de aplicações de Inteligência Artificial (IA) para pesquisadores e empresas de pequeno e médio porte a partir de aprendizado supervisionado. O estudo propõe um modelo básico para possibilitar que empresas de pequeno porte utilizem e se familiarizem com projetos de Inteligência Artificial de custos acessíveis e com ferramentas de uso free. A metodologia utilizada nessa pesquisa foi a pesquisa aplicada, quando o pesquisador aplica suas experiências e conhecimentos na solução de problemas do mundo real. Foi utilizada também a pesquisa bibliográfica através de consulta a livros, artigos, teses e dissertações para dar sustentação teórica aos estudos realizados. Durante os últimos dez anos de pesquisa desenvolvendo esse modelo, podemos avaliar o sucesso em 11 (onze) projetos concluídos e dois em andamento. O tempo de cada projeto variou de três a seis meses com acurácias sempre superior a 77%. O principal resultado é o próprio processo em detalhes. O processo com detalhes de suas fases usando ferramentas de baixo custo forjado ao longo de dez anos de pesquisas é a principal contribuição acadêmica que já apresentou resultados em aplicações no mundo real em pesquisa e em organizações pequeno e médio porte. O processo definido, permite que pequenas e médias empresas utilizem essa tecnologia usando ferramentas de baixo custo, gerando conhecimentos estratégicos até então desconhecidos aproximando suas estratégias das grandes corporações.

Palavras-chave: Processo, Tecnologia da informa, Inteligência Artificial, Aprendizado de máquina, BPMN

UM PROCESSO PRÁTICO PARA IMPLANTAR PROJETOS DE INTELIGÊNCIA ARTIFICIAL (IA) DE BAIXO CUSTO

RESUMO

A evolução tecnológica nos últimos tempos apresenta a Inteligência Artificial (IA) como o destaque do momento, capaz de alavancar muitas áreas de conhecimento como a saúde, gestão, segurança, educação, entre outras. O uso da IA faz emergir conhecimentos táticos e estratégicos que até então eram complexos o desenvolvimento e a captura. O objetivo dessa pesquisa foi desenvolver e apresentar um processo prático e de baixo custo para implantação de aplicações de Inteligência Artificial (IA) em empresas de pequeno e médio porte a partir de aprendizado supervisionado. A metodologia utilizada nessa pesquisa foi a pesquisa aplicada, quando o pesquisador aplica suas experiências e conhecimentos na solução de problemas do mundo real. Foi utilizada também a pesquisa bibliográfica através de consulta a livros, artigos, teses e dissertações para dar sustentação teórica aos estudos realizados. Durante os últimos dez anos de pesquisa desenvolvendo esse modelo, podemos avaliar o sucesso em 11 (onze) projetos concluídos e dois em andamento. O tempo de cada projeto variou de três a seis meses com acurácias sempre superior a 77%. Ao final da pesquisa, foi possível concluir e confirmar que é possível implantar um processo de IA de baixo custo com resultados relevantes para vários níveis de organizações, mas necessitando pra isso de capacitação e conhecimento nas áreas envolvidas no tema: Matemática, Estatística, Computação e a própria área de negócio onde será aplicada a IA.

Palavras-chave: Processo, Tecnologia da informação, Inteligência Artificial, Aprendizado de máquina, BPMN.

A PRACTICAL PROCESS FOR DEPLOYING LOW COST ARTIFICIAL INTELLIGENCE (AI) PROJECTS

ABSTRACT

Technological evolution in recent times presents Artificial Intelligence (AI) as the highlight of the moment, capable of leveraging many areas of knowledge such as health, management, security, education, among others. The use of AI brings out tactical and strategic knowledge that until then was complex to develop and capture. The objective of this research was to develop and present a practical and low-cost process for implementing Artificial Intelligence (AI) applications in small and medium-sized companies based on supervised learning. The methodology used in this research was applied research, when the researcher applies their experiences and knowledge in solving real world problems. Bibliographic research was also used through consultation of books, articles, theses and dissertations to give theoretical support to the studies carried out. During the last ten years of research developing this model, we can assess the success in 11 (eleven) completed projects and two in progress. The time of each project ranged from three to six months with accuracy always above 77%. At the end of the research, it was possible to conclude and confirm that it is possible to implement a low-cost AI process with relevant results for various levels of organizations, but requiring training and knowledge in the areas involved in the subject: Mathematics, Statistics, Computing and the business area where the AI will be applied.

Keywords: Process, Information Technology, Artificial Intelligence, Machine Learning, BPMN.

INTRODUÇÃO


A evolução tecnológica computacional tem origem nas décadas de 50 e 60 com os Mainframes, disponíveis só para grandes organizações públicas e privadas. Somente na década de 80 chega à democratização da tecnologia com os PCs (*Personal Computers*) e a TV por assinatura no final dos anos 80. Na década de 90 a internet, a telefonia móvel e a privatização das telecomunicações no Brasil impulsionam a tecnologia. Todo esse caminho foi necessário para que a partir de 2010 pudéssemos assistir à popularização das tecnologias com a chegada da computação em nuvem, smartphones modernos, mobilidade, e assim criar um ambiente tecnologicamente adequado para armazenar e processar grandes volumes de dados com capacidade para manipular textos, fotos, vídeos, TVs, links, tudo em alta velocidade e disponibilidade. É neste contexto moderno e atual que a IA (Inteligência Artificial) se desenvolve, possibilitando seu desenvolvimento e aplicação, acessível a todos que desejam se beneficiar dos seus poderosos recursos de geração de conhecimento a partir de grandes volumes de dados históricos.

Nos últimos anos a tecnologia vem atingindo altos níveis de disponibilidade, armazenamento e processamento, com isso tornou-se possível o uso com qualidade dos algoritmos de Inteligência Artificial (IA). As pesquisas no campo da IA, aumentam a cada dia e proporcionam novas descobertas sobre o aprendizado das máquinas (*Machine Learning*).

A Inteligência Artificial (IA) teve uma evolução histórica inicialmente lenta. Com muitos imaginando a IA semelhante ao que o cinema apresentava, com máquinas pensando e com emoções humanas, o interesse em investir nessas pesquisas por parte de empresas privadas não ocorreu nesse momento. Somente quando os sistemas baseados em IA tiveram por objetivo resolver problemas práticos e específicos empresariais, foi que despertou o interesse pelo investimento na área.

A importância do tema Inteligência Artificial pode ser observada nos artigos publicados no CONTECSI (International Conference on Information Systems and Technology Management) desde seu início em 2004. O Gráfico 1 abaixo, apresenta os “Termos indexados” mais citados sobre o tema em todos os eventos CONTECSI nas dezessete edições até 2020.

Gráfico 1 – Termos Indexados sobre IA no CONTECSI desde 2004.



Fonte: Elaborado pelo autor.

Segundo Luger (2013), a Inteligência Artificial (IA) revela um campo de estudo jovem e promissor, onde o principal interesse é encontrar um modo efetivo de entender e aplicar técnicas inteligentes para a solução de problemas e para o planejamento de utilização em uma gama de problemas práticos.

A relevância da implantação da IA para as organizações pode ser observada na pesquisa realizada pela PwC durante a pandemia, quando foram entrevistadas 200 empresas na Índia entre agosto e setembro de 2020 e 670 empresas no resto do mundo entre setembro e outubro de 2020. A pesquisa levantou informações sobre a adoção da IA nas organizações, conforme mostra o Gráfico 2 abaixo, é uma tendência muito forte para os próximos anos que o Brasil e a América do Sul precisam acompanhar.

Gráfico 2 – Tendência de adoção da IA no mundo durante a pandemia de Covid-19.



Fonte: Pesquisa Pwc (2020).

A transformação gerada pela inteligência Artificial pode proporcionar oportunidades para qualquer organização que esteja comprometida com a mudança e fizer os investimentos e planejamentos necessários. As startups digitais têm naturalmente uma facilidade de adaptação maior do que as empresas tradicionais, mas algumas empresas com décadas de história se adaptaram rapidamente e obtiveram sucesso nesse cenário da IA (IANSITI; LAKHANI, 2021).


Um ramo da IA que se tornou proeminente na pesquisa foi o aprendizado de máquina, do inglês *Machine Learning* (ML), com características específicas para resolver problemas relacionados à incerteza, notadamente na área de previsões e classificações, dentre outras abordagens, proporcionando a sua crescente utilização ao longo do tempo, culminando com o interesse em sua utilização por parte de empresas dos mais diversos ramos e portes.

Como todo ramo tecnológico e científico que exige especializações na sua condução, o aprendizado de máquina necessita da participação da equipe de especialistas com perfil de conhecimento e habilidades em análise de dados e construção de modelos matemáticos, além do conhecimento e prática com relação aos algoritmos específicos dos diversos paradigmas de IA que suportam o seu desenvolvimento histórico.

Muitos destes modelos de ML têm por objetivo resolver problemas práticos e empresariais relacionados à incerteza, tais como classificação ou previsão, dentre outros. Esses modelos

utilizam técnicas e formalismos matemáticos convencionais, tais como modelos estatísticos, atuariais, programação dinâmica, dentre outros. Normalmente esses modelos convencionais, atuam com a mesma estrutura lógica, que consiste na apresentação de uma matriz de dados, que constitui o conjunto de variáveis independentes. Essa matriz é submetida a uma função, representada pelo algoritmo ou conjunto de algoritmos, a qual leva o conhecimento ínsito no conjunto de dados, que é mapeado, a aproximar-se do alvo desejado, representado pela variável dependente, “y”. Teríamos então a representação, conforme a Figura 1 abaixo.

Figura 1 – Modelo de aprendizado de máquina.

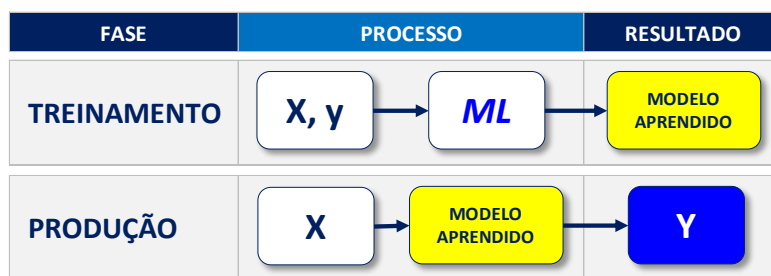


Fonte: Elaborado pelo autor.

Normalmente essa função é representada por um programa convencional de computador. A Inteligência Artificial no seu ramo de aprendizado de máquina (*Machine Learning*), propõe uma abordagem diferente. A partir de uma entrada de sinais, como matriz de dados e imagens, que contém as dimensões do conhecimento inerente ao problema proposto, ela extrai as características intrínsecas à matriz de sinais e otimiza um conjunto de parâmetros, definidos no paradigma utilizado de *machine learning*, de forma a aproximar o resultado da variável dependente, o seu alvo.

Esse conjunto de parâmetros estruturados em um formato de acordo com o algoritmo utilizado, define o que chamamos de modelo, que contém o aprendizado. Esse processo é chamado de “Treinamento do modelo”. Ele representa a função matemática que irá na fase de produção ser aplicado aos dados apresentados ao algoritmo que conduzirá ao objetivo final. Teríamos a representação do modelo como segue na Figura 2 abaixo.

Figura 2 – Modelo de Treinamento e Produção



Fonte: Elaborado pelo autor.

A presunção do modelo aprendido é que represente o mais aproximado possível a função real, representada pelo conjunto de sinais de entrada. Como podemos deduzir do exposto, a fase mais importante da concepção de um modelo de implementação de IA, está na definição da matriz de sinais que deve representar de forma mais nítida e fiel possível a realidade proposta. Perseguimos por modelo ideal, uma representação em que as variáveis independentes sejam efetivamente e estatisticamente independentes entre si e que a variável dependente seja realmente dependente do conjunto de variáveis independentes.


Sabe-se que é difícil na vida real, obter-se a pureza desse modelo, mas espera-se que para uma modelagem adequada esse modelo proposto se aproxime ao máximo do modelo real. Em outras palavras, espera-se que na construção do modelo de dados considerem-se as variáveis com significado que represente as dimensões do conhecimento existente no espaço definido pelo domínio do problema em pauta, facilitando a construção do modelo matemático gerado pelo processo de treinamento do algoritmo, cuja otimização de seus parâmetros ocorrerá com resultados mais significativos.

Como se pode deduzir, da necessidade de especialização da equipe com respeito ao conhecimento necessário para um bom trabalho que traga resultados consistentes e corretos para a empresa, o custo da implementação de tal tecnologia pode não permitir seu acesso a empresas de pequeno e médio porte. Esse trabalho tem por objetivo facilitar o entendimento e a condução das fases de implementação de um modelo de *machine learning* eficiente e de baixo custo em empresas de pequeno e médio porte. Com isso tenta-se minimizar a necessidade do conhecimento complexo e profundo da análise de dados e construção do modelo de dados, como problema inicial. Em seguida a apresentação de modelos com abordagens simples e seguras dos algoritmos usados para essas aplicações mais comuns nas empresas.

Espera-se que o conhecimento aqui exposto, aplicado em todas as fases do desenvolvimento de um modelo de *machine learning* venha propiciar o acesso e utilização dessa tecnologia de ponta para muitas empresas de pequeno e médio porte, pesquisadores independentes, instituições governamentais e não-governamentais que planejam utilizar esse mecanismo de alavancagem e conhecimento estratégico dos negócios.

Os eventos CONTECSI USP são eventos de grandes impactos na pesquisa científica e tecnológica no Brasil desde 2004, mostrando a evolução e interesse pela comunidade acadêmica e empresarial sobre Sistemas de Informação, Computação, Gerenciamento de Projetos e Inteligência Artificial, entre outros. O Gráfico 3 abaixo, nos mostra a evolução das publicações sobre o tema IA, a partir das pesquisas submetidas e aceitas. Em 2008 no 5th CONTECSI tivemos apenas seis trabalhos sobre o tema, mas nos últimos três anos (2018, 2019 e 2020) o interesse sobre o tema se multiplicou, nos deixando com boas expectativas para o 18th CONTECSI em 2021.

Gráfico 3 – Evolução das pesquisa sobre IA no CONTECSI desde 2004.



Fonte: Elaborado pelo autor.

Atualmente, quando nos deparamos com notícias de que grandes corporações usam IA em grande escala, não é novidade, visto que eles possuem grandes equipes de tecnologia

e pesquisa, grandes investimentos e financiamento do desenvolvimento de pesquisas, o que torna relativamente fácil aplicar a IA em suas atividades.

Veja alguns exemplos de uso da IA por grandes corporações: a Accenture usa *Machine Learning* (ML) para avaliar currículos de seus funcionários e candidatos a funcionários; A Lennox usa software para prever defeitos nos equipamentos que dá manutenção com acerto de 90% em até quatro horas antes do defeito; A American Travel usa ML para ajudar seus clientes em viagens corporativas, disponibilizando melhores tarifas aéreas e de hotéis; A Amazon faz indicação de compras baseada no comportamento de outros compradores; A Mastercard usa ML para detectar anomalias que sugerem ataques de Hackers e tentativas de fraudes; A NFL calcula e apresenta ao vivo durante suas transmissões, as análises preditivas das jogadas, entre outras aplicações.

O objetivo dessa pesquisa é apresentar um processo prático e de baixo custo para implantação de aplicações de Inteligência Artificial (IA) usando aprendizado supervisionado em empresas de pequeno e médio porte, facilitando e tornando possível o acesso dessas organizações ou grupos de pesquisas a essa tecnologia revolucionária e disruptiva dos nossos tempo.

REFERENCIAL TEÓRICO

O logicismo

A ideia da lógica formal pode ser traçada até os filósofos da Grécia antiga, mas o desenvolvimento matemático começou mesmo com o trabalho de George Boole, que definiu os detalhes da lógica proposicional ou lógica booleana em 1847. Gottlob Frege (1848-1925) ampliou a lógica de Boole para incluir objetos e relações, criando a lógica de primeira ordem, e Alfred Tarsky (1902-1983) introduziu a teoria de referência que mostra como relacionar os objetos de uma lógica a objetos do mundo real (NORVIG; RUSSEL, 2013).

Segundo Russell (2016), o princípio lógico também define princípios óbvios conhecidos tradicionalmente de “Leis do pensamento”, são eles:

- a) A lei da identidade: “O que é, é”;
- b) A lei da contradição: “Nada pode conjuntamente ser e não ser”;
- c) A lei do terceiro excluído: “Tudo tem de ou ser ou não ser”.

A inferência é um sinal de inteligência que marca a superioridade do homem em relação a máquina. Ao mesmo tempo, o uso da inferência e da lógica tradicional é tão insensato que deixa dúvidas com respeito a esta superioridade; a inferência silogística desde Aristóteles até Bacon, é uma coisa que uma simples máquina de calcular pode realizar melhor do que um professor (RUSSELL, 2009).

A partir do estudo da lógica como um elemento filosófico, o homem desenvolveu os algoritmos para solucionar problemas, posteriormente automatizados por programas de computador. Os programas agora utilizam recursos computacionais modernos para simular a inteligência humana com os algoritmos de inteligência artificial.

Algoritmos

A palavra *algoritmo* vem de Al-Khowarazmi, um matemático persa do século IX, cujos escritos também introduziram os numerais arábicos e a álgebra na Europa. Acredita-se

que o primeiro algoritmo não trivial seja o algoritmo de Euclides para calcular o maior divisor comum (NORVIG; RUSSELL, 2013).

Segundo Turban e Volonino (2013), um algoritmo é um conjunto de regras ou instruções elaboradas para resolver um problema em um número finito de etapas.

Um algoritmo pode ser associado a uma estratégia para resolver um determinado problema. Os dados do problema constituem a ENTRADA ou os dados do algoritmo. A solução do problema constitui a SAÍDA. Um algoritmo pode ser representado por uma função “f”, a qual associa uma saída $S = f(E)$, a cada entrada E. Diz-se então que o algoritmo computa a função “f”, conforme a Figura 1 abaixo (SZWARCFITER, 2018).

Figura 3 – Modelo de um algoritmo.



Fonte: Modelo de Szwarcfiter, 2018.

O estudo de algoritmos e de lógica de programação é essencial no contexto de criação de um software ou programa de computador. Como definição geral, um algoritmo representa um conjunto de regras para a solução de um problema. Dessa forma, uma receita para elaborar um alimento é um exemplo de algoritmo (informal e impreciso), pois descreve as regras necessárias para a conclusão do seu objetivo (FURLAN *et. al.*, 2019).

A Filosofia, origem do Logicismo e conseqüentemente dos algoritmos, pode ser dividida em valores Teóricos e Práticos (do espírito). Entre os valores teóricos estão a Teoria do Conhecimento Científico e a Teoria da Ciência, é nesta vertente que a lógica se desenvolve para construir algoritmos que vão desde o formalismo simples de Aristóteles até os programas modernos de computadores executando algoritmos de Inteligência Artificial.

Inteligência Artificial (IA)

A Inteligência Artificial tem como objetivo aplicar técnicas inteligentes na solução de problemas complexos usando computadores ou máquinas inteligentes. São várias as definições de inteligência artificial usadas na literatura, como segue abaixo:

“IA é a parte da Ciência da Computação que se preocupa em desenvolver sistemas computacionais inteligentes, isto é, sistemas que exibem características, as quais nós associamos com a inteligência no comportamento humano - por exemplo: Compreensão da linguagem, aprendizado, raciocínio, resolução de problemas etc.” (BARR; FEIGENBAUM, 1981).

“IA é o estudo de faculdades mentais através do uso de modelos computacionais” (CHARNIAK; McDERMOTT, 1987).

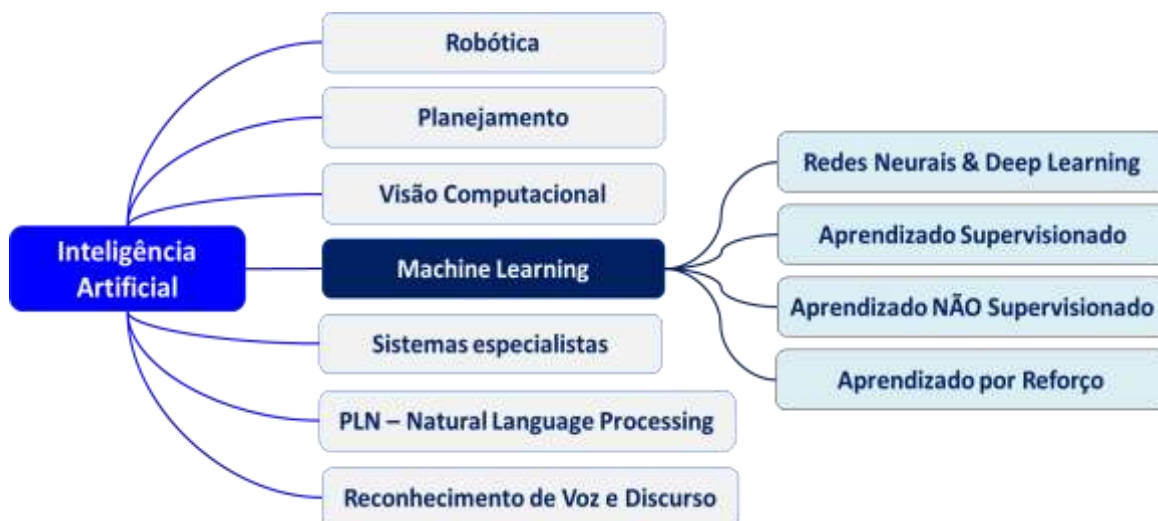
“IA é a arte de criar máquinas que executam funções que requerem inteligência quando executadas por pessoas” (KURZWEIL, 1990).

“IA é o estudo de como fazer os computadores realizarem coisas que, no momento, as pessoas fazem melhor” (RICH; KNIGHT, 1990).

Combinando os conceitos acima, chegamos ao conceito mais usado na academia: “IA é o campo da Ciência da Computação que está preocupado com a automação do comportamento inteligente”.

A Inteligência Artificial é formada por vários tipos de aplicações. A Figura 4 abaixo, nos mostra as principais aplicações da IA que são utilizadas nas pesquisas científicas e no mundo organizacional no momento.

Figura 4 - Tipos de aplicações da IA.



Fonte: Elaborado pelo autor.

A nossa pesquisa focou na utilização de *Machine Learning* (Aprendizado de Máquina). *Machine Learning* é considerado um subcampo da inteligência Artificial com suas subdivisões e seus algoritmos também podem ser utilizados em outros subcampos, como: *Natural Language Processing* (NLP), *Speech* (Análise de voz e discurso) e Visão computacional.

Machine Learning (Aprendizado de Máquina)

O Aprendizado de máquina ocorre quando um programa aprende a partir da experiência E , em relação a uma classe de tarefas T , com medida de desempenho P , se seu desempenho em T , medido por P , melhora com E , isto é, ele melhora a realização de uma tarefa a partir da experiência (MITCHELL, 1997).

O aprendizado de máquina pode ser supervisionado, não supervisionado ou por reforço. Existem algoritmos específicos para cada tipo de aprendizado, os principais algoritmos de aprendizado supervisionado são: K-NN, Árvore de decisão, Naive Bayes, Perceptron/Adaline e MLP (*Multi-Layer Perceptron*), os principais algoritmos de aprendizado não supervisionado são: K-means, DBSCAN, Métodos hierárquicos, PCA e SOM, enquanto os principais algoritmos de aprendizado por reforço, são: Q-learning, SARSA, DDPG e MPC.

As principais técnicas de aprendizado de máquina estão representadas na Figura 5 abaixo, segmentadas nos três tipos: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço.

Figura 5 - Principais técnicas e algoritmos de Aprendizado de Máquina.



Fonte: Elaborado pelo autor.

Diz-se que um algoritmo usa aprendizado Supervisionado quando ele utiliza características prévias para prever o futuro, o modelo mais conhecido é a regressão linear que minimiza os erros quadráticos entre a variável predita e o valor real da variável. Já o aprendizado Não Supervisionado busca agrupar objetos ou fatos com características semelhantes ou próximas, a técnica mais conhecida é a clusterização ou agrupamento. Enquanto o aprendizado por Reforço é o treinamento de modelos para tomar a melhor sequência de decisões. O agente aprende a atingir uma meta em um ambiente incerto e complexo, utilizando métodos de tentativa e erro para encontrar a melhor solução para o problema (DATA SCIENCE ACADEMY, 2021).

Modelagem de processos

Os processos organizacionais são importantes para as organizações, pois definem como as atividades devem ser realizadas dentro da organização. Processo é uma sequência de atividades com um objetivo específico. Ao realizar todos os passos de um processo, o resultado será alcançado (CAMPOS, 2013).


O mapeamento de processos é uma ferramenta com objetivo de aperfeiçoar os processos existentes ou de implantar uma nova estrutura voltada para processos. É uma técnica utilizada por empresas para entender de forma clara e simples como uma área, equipe ou departamento está executando suas principais tarefas, representando cada passo dessa operação em entradas, saídas e ações.

Essa visão de compreensão e documentação é fundamental para diversas metodologias de melhoria de processos, como o Seis Sigma e o Lean Manufacturing: é a partir de um mapa bem estruturado do processo que sugestões de melhoria e pontos de atuação dessas metodologias podem ser levantados e observados com mais detalhe.

A Análise e Modelagem de Processos permite descobrir, identificar, classificar e mapear os processos-chave e os processos críticos (VALLE e OLIVEIRA, 2009).

A gestão de processos de negócios, conhecida como BPM – *Business Process Management*, é uma técnica fundamental de gestão que inclui métodos e ferramentas para suportar as fases do ciclo de vida de processos de negócio. A Figura 6 abaixo, apresenta um exemplo de Processo mapeado usando BPMn (*Business Process Model and Notation*) para aplicação de IA utilizado em uma das pesquisas realizadas com o modelo proposto.

Figura 6 – Processo mapeado usando BPMn para utilização de IA.



Fonte: Elaborado pelo autor.

Em curto espaço de tempo utilizando a BPM, as empresas melhoram a rentabilidade, reduzem desperdícios e custos, no longo prazo, a BPM ajuda a manter as companhias sensíveis às mudanças de negócios (TURBAN; VOLONINO, 2013).

METODOLOGIA

A metodologia de pesquisa utilizada foi a qualitativa, quando estudamos um tema para extrair conhecimentos não padronizados. Pesquisa Qualitativa é um meio para explorar e para entender o significado que os indivíduos ou os grupos atribuem a um problema social ou humano (CRESWELL, 2010).

Quanto aos objetivos, podemos definir como pesquisa aplicada, pois gerou novos conhecimentos que podem ser aplicados no mundo real em benefício das organizações, grupos de pesquisas ou nas comunidades interessadas no tema. Na pesquisa aplicada, o investigador é movido pela necessidade de contribuir para fins práticos mais ou menos imediatos, buscando soluções para problemas concretos (CERVO; SILVA; BERVIAN, 2007).

Quanto aos meios, foi usada a pesquisa bibliográfica para direcionar o trabalho e dar sustentação teórica. A revisão bibliográfica procurou discorrer sobre os temas que cercam a computação, gestão de processos e inteligência artificial. Organizar uma bibliografia significa buscar aquilo cuja existência ainda se ignora. O bom pesquisador é aquele que é

capaz de entrar em uma biblioteca sem ter a mínima ideia sobre um tema e sair dali sabendo um pouco mais sobre ele (ECO, 2005).

Também foi utilizado como método a pesquisa bibliográfica, composta de estudos através de livros, artigos, teses, dissertações etc., visando criar um conteúdo completo e seguro sobre o tema estudado.

O modelo proposto não tem a intenção de exaurir todas as possibilidades das boas práticas de modelagem, mas expor aquelas que consideramos mais importantes. Certamente, pode precisar de ajustes, evoluções e deve ser avaliado para cada solução em que será usado. O modelo se aplica prioritariamente às aplicações de IA que utilizam *Machine Learning* com aprendizado supervisionado.

MODELO PROPOSTO

O modelo proposto nesta pesquisa foi desenvolvido, otimizado e aplicado durante as várias pesquisas e aplicações desenvolvidas pelos autores, desde 2011. No decorrer do tempo o processo foi se apresentando e evoluindo, tornando-se um padrão definido e em condições de divulgação para as organizações e academia. O processo se apresentou naturalmente no decorrer dos anos, no início não era nossa intenção desenhar ou propor um processo padronizado, o processo surgiu da utilização e do sucesso. Dessa forma, essa pesquisa pretende disponibilizar acesso de baixo custo às técnicas de IA para uso de *Machine Learning* com aprendizado supervisionado para todos os interessados nessas aplicações.

Os macroprocessos são agrupamentos de processos necessários para produzir uma solução, produto ou atingir um objetivo. O Diagrama de Contexto abaixo, representado pela Figura 7, apresenta uma visão geral dos macroprocessos necessários para o desenvolvimento de um Modelo de inteligência Artificial, agrupados em Fases, que serão detalhadas a seguir.

Figura 7 – Diagrama de contexto detalhado em Fases.



Fonte: Elaborado pelo autor.

O Diagrama de Contexto proposto está dividido em quatro fases: Projeto; Treinamento e testes; implantação e Utilização ou estratégias de uso. Segue abaixo o detalhamento das fases.

Fase I – Projeto

Agora vamos começar nosso projeto, aqui a equipe do projeto define a “Dor” que incomoda, ou seja, o problema que se deseja resolver. É indicado que a equipe do projeto utilize uma das metodologias de Gerenciamento de Projetos disponíveis no mercado, como: PMBOK, PRINCE2, Kanban, Scrum, entre outros.

A identificação do problema ou “Dor”, como alguns chamam, é o início de todo processo. Nesse momento deve ser avaliado exaustivamente a necessidade de aplicar ou não os esforços nessa demanda e a partir da “Dor” definir qual o objetivo que o modelo deve alcançar. Nesse momento deve ser discutido sobre a Fase IV, “A utilização”, pois é necessária a definição mínima de como serão usados os resultados para minimizar ou exterminar a “Dor” e qual valor esse modelo vai agregar ao negócio. Aqui, deve-se definir com precisão e clareza o universo do problema e o que se pretende obter com ele.

Definidos a “Dor” e o objetivo, começa então o planejamento, que envolve a definição da equipe, custos, cronograma, *stakeholders*, áreas envolvidos e o plano de coleta dos dados.

Na identificação, coleta e modelagem dos dados, enfrentamos o primeiro grande desafio de uso da IA: Existem dados disponíveis que expliquem a questão estudada ?; Os dados são de fácil acesso ?; As variáveis explicativas disponíveis para o desfecho desejado são suficientes ?

Nesta fase pesquisamos as situações inerentes ao problema que interferem no objetivo almejado e delas extraímos as variáveis aleatórias que representem as dimensões de conhecimento dessas situações e os dados necessários à sua resolução são extraídos das fontes de dados. Começa agora a definição das variáveis explicativas para o desfecho desejado: Quais são as variáveis ?; As fontes dos dados são confiáveis ?; A amostra de dados disponível é suficiente para desenvolver o modelo ?; É possível usar dados sintéticos complementares ?

Após extrair os dados, estes passarão pelo processo chamado de “*Data Wrangling*” ou preparação dos dados, depois pelo processo “*Data Munging*” ou manipulação dos dados. Trata-se do processo de transformar e mapear os dados brutos extraídos em um formato mais adequado à aplicação dos algoritmos de *Machine Learning*. Esse processo consiste na limpeza e correção dos dados nulos e faltantes e padronização das escalas das variáveis aleatórias. Isso é feito com o processamento dos dados utilizando-se de pacotes de software estatísticos.

Quanto à qualidade, os dados utilizados devem ser de alta qualidade, embora nem sempre isso é possível ou estão disponíveis como desejamos, isso significa que devem ser submetidos aos critérios que medem suas qualidade, como a validade.

A validade

A validade mede o grau de conformidade das medidas com as regras ou restrições estabelecidas na solução do problema. É frequente encontrar as seguintes restrições nos dados coletados:

Restrições de tipos de dados: Quando os valores de determinada coluna exigem um tipo de dado específico, exemplo: data.

Restrições de intervalo: Quando, por exemplo, números precisam estar dentro de um intervalo, a exemplo da faixa de idades, que definem valores mínimos e máximos.

Restrições obrigatórias: Quando certas colunas não permitem valores nulos.

Restrições exclusivas: Quando valores são exclusivos por elemento, por exemplo, duas pessoas não podem ter a mesma matrícula.

Restrições *Set-Membership*: Quando os valores são de um conjunto discreto, por exemplo, o grau de escolaridade.

Restrições de chave estrangeira: Quando existe uma associação definida por valores exclusivos em outra tabela de dados. Por exemplo, o CRM (Conselho Regional de Medicina) de um médico deve corresponder a um determinado médico em outra tabela.

A Acurácia: Determina o grau de conformidade de uma medida a um valor dado como padrão ou verdadeiro, é uma medida de precisão.

A Completude: Os valores de todas as colunas da matriz de representação dos dados representam todas as medidas necessárias para a solução do problema, portanto, todas as medidas são conhecidas.

A Consistência: É a garantia de que um conjunto de dados é equivalente a todos os sistemas. Quando dois itens de dados são contraditórios em um conjunto de dados, há uma inconsistência.

A Uniformidade: É a garantia de que em um conjunto de dados, as medidas são utilizadas usando a mesma unidade.

Para garantir a qualidade e a preparação dos dados passamos pelos seguintes passos:

Detectar e marcar dados nulos e faltantes (*missing values*): É o processo de detectar os dados nulos, corrompidos, faltantes ou imprecisos constantes nas colunas do *dataset*.

Excluir dados marcados como nulos: É o processo de eliminar as linhas que contenha algum valor nulo ou faltante, caso o volume de linhas seja pequeno e não prejudique a análise dos dados.

Incluir dados faltantes ou nulos: É o processo de prever, através de recurso estatístico, os valores faltantes e incluir nas colunas.

Detectar valores discrepantes: É o processo de identificar os *outliers*.

Padronizar as escalas: É o processo de pré-processamento para padronizar as escalas das colunas de dados.

Nessa momento, os dados são submetidos a algoritmos estatísticos para analisar a sua distribuição, correlação das variáveis independentes entre si e com a variável dependente,

análises da dispersão dos dados, entre outros. O conhecimento estatístico é importante para a análise e classificação das variáveis.

Os dados compilados devem formar uma matriz, contendo as variáveis independentes, do inglês *Features*, que corresponde ao conjunto X, e a variável dependente, do inglês *Target*, que corresponde ao Y. Essa matriz de dados torna-se o Set de treinamento do modelo.

Como podemos observar no detalhamento da Fase I, são várias tarefas exaustivas, as vezes pouco atraentes para os profissionais, mas que são fundamentais para a boa qualidade do modelo e seus resultados.

Fase II – Treinamento e Testes

O início dessa fase é marcado pela divisão dos dados em dois arquivos: Treinamento e Testes. O Arquivo de dados será dividido de forma aleatória em dois arquivos na seguinte proporção: Arquivo de treinamento com 70% dos dados e Arquivo de Testes com 30% dos dados. Essa proporção não é impositiva, ajuste aos seus dados, pode ser também 60% e 40%, ou outras proporções que avaliar adequada.

Para o treinamento, indicamos ainda o uso da técnica de *K-Fold* em *Cross Validation* (Validação Cruzada), isto é, misturando os dados de treino e teste em 10 (dez) grupos diferentes e cruzando-os, conforme mostra a Figura 8, gerando uma única matriz de pesos sinápticos. Dessa forma, a mesma base de dados acaba gerando 10 (dez) *datasets* diferentes de treinamento.

Figura 8 – Técnica de *K-folds* e *Cross Validation*.



Fonte – Tese de Doutorado (AGUIAR, 2019).

A validação cruzada (*Cross Validation*) é uma ferramenta estatística conhecida por dividir aleatoriamente o conjunto de dados em um conjunto de treinamento e um conjunto de testes. A motivação aqui é validar o modelo com um conjunto de dados diferente daquela usado para definir os parâmetros. O uso da validação cruzada é indicado quando é necessário projetar uma rede neural grande e o objetivo é uma boa generalização. Dessa forma se espera que a rede se torne bem treinada de modo que aprenda o suficiente sobre o passado para generalizar o futuro (HAYKIN, 2001).

O método de validação cruzada que indicamos é chamado de *K-folds*, que consiste em dividir os dados em 10 (dez) subconjuntos mutuamente exclusivos, que de forma circular,

seleciona sete partes para treinamento e três partes para os testes. Após k-iterações calcula-se a acurácia para obter uma medida mais confiável.

Agora faremos o “Treinamento do Modelo” com os dados selecionados por 100 (cem) épocas, isto é, o modelo de aprendizado será executado cem vezes para a base de dados de treinamento, e esse processo repetido por 10 (dez) vezes ou *folders* com bases de treinamentos diferentes. Neste momento é indicada a utilização de quatro ou cinco modelos de Aprendizado de Máquinas (*Machine Learning*), normalmente usamos: Regressão Linear (Múltiplas variáveis); Rede Neural MLP (*Multi-layer Perceptron*); Fuzzy e *K-Means Clustering*.


A partir de agora faremos o “Teste de Acurácia do Modelo”, isto é, o arquivo de teste será submetido ao modelo para averiguação da acurácia, isto é, aplicamos o modelo final no arquivo que não foi utilizado no treinamento.

A Acurácia é a medida que calcula o quanto o resultado do modelo se aproxima da realidade ou a quantidade de objetos ou fatos classificados corretamente pelo algoritmo. Nesta fase utilizamos a Curva ROC (*Receiver Operating Characteristic*) como teste de acurácia para escolher os modelos de melhores performances.

A validação do modelo consiste em avaliar os resultados alcançados e ajustar os dados ou o modelo até encontrar o estágio ideal para finalizar o processo. Essa atividade pode ser repetida várias vezes até encontrar o resultado considerado ideal. Neste ponto o modelo treinado é armazenado para aplicação em novos dados desconhecidos do mundo real.

O processo descrito nas fases acima também pode ser analisado e visualizado na Figura 9 abaixo, que apresenta o fluxo do processo de aprendizado de máquina utilizado até a geração da Matriz final.

Figura 9 - Processo de Aprendizado e geração da Matriz Final.



Fonte – Tese de Doutorado (AGUIAR, 2019).

Fase III – Implantação

Esta fase se caracteriza pela utilização do modelo no mundo real, isto é, agora com o modelo treinado e identificado qual a sua melhor formação, podemos usar em um processo de produção para inferir a informação desejada. A informação gerada será utilizada para a tomada de decisão nas estratégias planejadas.

Fase IV – Utilização e planejamento de ações

Agora chegou o momento de utilizar os conhecimentos gerados pelo modelo de IA, uma fase executada e planejada pela área demandante. E agora ? Como vamos usar esse conhecimento estratégico ? Para que servem essas informações inferenciais ? Que estratégias poderemos aplicar para alcançar os objetivos propostos ?

EXEMPLOS DE APLICAÇÕES REAIS

O modelo proposto evoluiu no decorrer do tempo, pois desde 2014, sem saber que era possível, um modelo foi se desenhando e amadurecendo em nossas pesquisas científicas e aplicações corporativas com resultados animadores. O Quadro 1 abaixo, relaciona todas as iniciativas que culminaram nesse modelo que aqui apresentamos.

Quadro 1 – Relação de projeto de pesquisas usando o modelo proposto.

ANO	ÁREA	PROJETOS DE PESQUISAS	PESQUISA CIENTÍFICA PUBLICADA
2011	SAÚDE	Uma Metodologia de DETECÇÃO DE FRAUDES e abusos nos serviços de odontologia: Aplicações em uma OPS	DISSERTAÇÃO de Mestrado UECE
2014	SAÚDE	O uso da Inteligência Artificial na detecção de fraudes e abusos em TRATAMENTOS ODONTOLÓGICOS	12th CONTECSI USP 2015
2015	SAÚDE	Desenvolvimento de modelos preditivos de MORTALIDADE INFANTIL com base em Inteligência Artificial no Ceará	TESE de Doutorado UFC-CE; 13th CONTECSI USP 2016; XI Seminário de Pesquisa da ESTÁCIO 2019
2018	SAÚDE	Uso da Inteligência Artificial na SAÚDE COLETIVA : A visão de profissionais de Tecnologia da informação	12º ABRASCO 2018; 1º ENESF 2018
2018	SAÚDE	Uso da IA para classificar os FEMINICÍDIOS ocorridos em Pernambuco - 2018	XI Seminário de Pesquisa da ESTÁCIO 2019
2019	SAÚDE	Uso da IA para predição de ACIDENTES DE TRÂNSITO na Região Metropolitana de Fortaleza (RMF)	1º ConGPr 2020; XII Seminário de Pesquisa da ESTÁCIO 2021; Submetido ao 11º ABRASCO 2021
2020	SAÚDE	Aplicação de rede convolucional para mapeamento de usuários de uma UPA 24hs	Submetido ao 18th CONTECSI USP 2021
2020	SAÚDE	Predição do desfecho em pacientes da COVID-19 em Sobral-CE (2020): Alta ou Óbito	Aplicação real na 1ª onda da COVID-19 em 2020
2021	SAÚDE	Uso da IA na predição da qualidade do sono na PRIMEIRA INFÂNCIA baseado em Aprendizado Supervisionado	Em desenvolvimento: Projeto de Iniciação Científica na Estácio Ceará 2021 junto ao IPREDE
2018	SEGURANÇA	Deteção e RECONHECIMENTO FACIAL utilizando o algoritmo LBPH e JAVACV	16th CONTECSI USP 2019; XI Seminário de Pesquisa da ESTÁCIO 2019
2018	SEGURANÇA	Uso da IA para Predição de ASSALTO À BANCOS no estado do Ceará	16th CONTECSI USP 2019; XI Seminário de Pesquisa da ESTÁCIO 2019
2020	SEGURANÇA	Uso da IA para Predição de ATAQUES TERRORISTAS no estado do Ceará	Em desenvolvimento
2021	SEGURANÇA	Uso da IA para Predição de ASSALTO À PEDESTRES em Fortaleza-CE	Em desenvolvimento

Fonte - Elaborado pelo autor.

A Dissertação de Mestrado defendida em 2011 com o Tema: “Uma metodologia de detecção de fraudes e abusos nos serviços de Odontologia: Aplicação em uma Operadora de

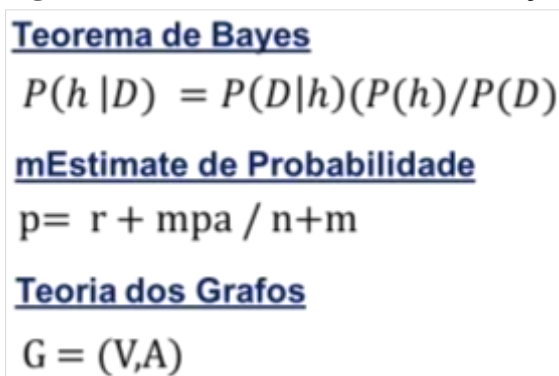
Planos de Saúde”, foi o marco inicial para o desenvolvimento dessa lista de aplicações usando IA. Em 2014 esse projeto foi implantado em uma Operadora de Planos de Saúde no Ceará e até hoje traz benefícios operacionais para essa organização.

Essa Dissertação de Mestrado pesquisou o problema das fraudes e abusos recorrentes nos tratamentos odontológicos de uma Operadora de Planos Odontológicos. Para isso adotou a metodologia de pesquisa mista e identificou, juntamente com os auditores, as variáveis explicativas da fraude e abuso constantes em todos os casos estudados. Construiu-se um modelo de dados multivariados explicativo do problema de fraude e abuso. Constatou-se pelos casos existentes e pela literatura, que os padrões de fraudes e abusos dinamicamente mudavam na medida em que eram descobertos e transformados em regras (FONTENELLE, 2011).

Nesta etapa, verificou-se que a solução para o problema residia na construção de modelos e da utilização de técnicas inteligentes que detectassem de forma automática e dinâmica esses padrões existentes no conjunto dos tratamentos odontológicos. A construção de um modelo aborda dificuldades inerentes à precisão e à capacidade de refletir todas as nuances do problema. Como técnica inteligente entendeu-se como a melhor solução o uso de classificadores que buscam padrões embora seja vulnerável aos padrões não previstos no modelo (FONTENELLE, 2011).

A Figura 10 abaixo, apresenta algumas técnicas utilizadas na Dissertação de Mestrado que permitiu a detecção de fraudes, trazendo benefícios para a operadora, como: Redução do pagamento de tratamentos indevidos; Estrutura mais eficiente de auditoria clínica; Novas estratégias de relacionamentos, Redução da Sinistralidade, entre outras.

Figura 10 – Técnicas utilizadas na detecção de fraudes.



Fonte: Dissertação de Mestrado FONTENELLE (2011).

A Tese de Doutorado defendida em maio de 2019 com o Tema: “Uso da inteligência Artificial para Predição da Mortalidade Infantil no Ceará”, também aplicou o modelo proposto com ações e fases semelhantes. O modelo utilizou uma estrutura de Comitê com 05 (cinco) Redes Neurais em *Stacked* (empilhamento) com Rede Neural *Deep Learning* com 04 (quatro) camadas e estratégia de *split* dos dados com *K-Folds* (K=10) e modelo final ajustado com *Logistic Regression*, obtendo resultados satisfatórios e acurácia superior a 98%.

Nesse modelo foi utilizado um processo de preparação, tratamento, processamento e avaliação dos dados, seguindo o padrão já utilizado em outros projetos, embora representado abaixo de forma diferente na Figura 11 que detalha as atividades.


Figura 11 – Fases para geração do Modelo preditivo de Mortalidade Infantil.



Fonte – Tese de Doutorado (AGUIAR, 2019).

O Gráfico 4 apresenta o treinamento ($K\text{-fold} = 2$) com as informações das acurácias obtidas nas 100 (cem) épocas executadas. Esse treinamento obteve os melhores resultados quando aplicado no *dataset* de teste da Mortalidade Infantil com acurácia de 98,04%. Nesse gráfico é possível observar uma curva crescente do aprendizado.

Gráfico 4 - Gráfico de Acurácia do melhor treinamento ($K\text{-fold} = 2$).



Fonte – Tese de Doutorado (AGUIAR, 2019).

CONCLUSÕES

Essa pesquisa mostrou que a IA não está tão distante das pequenas e médias empresas, a IA é para todos e está presente cada vez mais no nosso dia a dia. Estas empresas que desejam usar essas tecnologias e possuem pequenas equipes de TI e de negócios, já devem começar a preparar suas equipes para esse momento, estimule e incentive o estudo e a profissionalização das suas equipes. As áreas de TI e de negócios devem estudar: Estatística; Matemática; Ciência de dados; Linguagens de programação como Python e R; BI (*Business Intelligence*) e as boas técnicas de gerenciamento de projetos como PMBOK e Scrum. Incentive suas equipes à graduação, especialização e mestrado. Não existe colheita sem o esforço da plantação.

A experiência adquirida nesses últimos 10 (dez) anos desenvolvendo pesquisas científicas e projetos para empresas, moldou naturalmente esse processo, facilitando o desenvolvimento deles e hoje nos permite compartilhar no 18th CONTECSI, como mostra a relação de 11 (onze) projetos concluídos e mais dois em andamento.

Concluindo, o estudo mostrou que o modelo proposto pode ser aplicado em vários tipos de projetos de IA, possibilitando acesso de baixo custo à essa tecnologia por pesquisadores independentes, pequenas e médias empresas. Dessa forma pretendemos colaborar com a divulgação de conhecimentos adquiridos ao longo de 10 (dez) anos de pesquisas e trabalhos profissionais que acreditamos ser capaz de auxiliar a academia e as pequenas organizações. A IA chegou para ficar e para todos.

Todos os projetos desenvolvidos nesse período de pesquisa utilizaram ferramentas de uso *free*, como: Python, R, Anaconda, Mysql, Java, Pandas, Tensorflow, Numpy, Scikit-Learn, Keras, Matplotlib, Statsmodels, Seaborn, entre outros, viabilizando o baixo custo dos projetos.

Ainda, como trabalho futuro, desejamos desenvolver um livro técnico, explicando com mais detalhes o processo e as experiências adquiridas com esse modelo, para que no próximo CONTECSI, quem sabe presencialmente, possamos lançar o livro baseado nesse artigo, junto com nossos colegas pesquisadores.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, W. S. Desenvolvimento de modelos preditivos de mortalidade infantil com base em inteligência artificial no estado do Ceará. Tese de Doutorado – Universidade Federal do Ceará, Faculdade de Medicina, Programa de Pós-graduação em Saúde Coletiva, Fortaleza-CE, 2019.

BARR A; FEIGENBAUM E. A. The Handbook of Artificial Intelligence, volume I-II. Willian Kaufmann Inc., Los Altos, California, 1981.

CAMPOS, André L. N. A modelagem de processos com BPMN. 1ª ed. Rio de Janeiro: Ed. Brasport, 2013.

CERVO, Amado L.; SILVA, Roberto da; BERVIAN, Pedro A. Metodologia Científica. 6ª ed. São Paulo: Ed. Pearson Prentice Hall, 2007.

CRESWELL, John W. Projeto de pesquisa: Métodos qualitativo, quantitativo e misto. 3ª ed. Porto Alegre: Artmed, 2010.

CHARNIAK, Eugene; McDERMOTT, Drew. Introduction to artificial intelligence. Addison-Wesley Logman Publishing Co., Boston, USA, 1987.

DATA SCIENCE ACADEMY. Deep Learning Book, 2021. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acessado em: 03 Junho. 2021.

ECO, Umberto. Como se faz uma tese. 20ª edição, São Paulo: Perspectiva, 2005.

FONTENELLE, José Mário B. Uma Metodologia de Detecção de Fraudes e Abusos nos Serviços de Odontologia: Aplicação em uma OPS. Dissertação de Mestrado, Universidade Estadual do Ceará. Fortaleza-CE, 2011.

FURLAN, Marco A.; GOMES, Marcelo M.; SOARES, Marcio V.; CONCILIO, Ricardo. Algoritmos e lógica de programação. 3ª ed. São Paulo: Editora Cengage, 2019.

HAYKIN, Simon. Redes neurais: princípios e prática. 2ª edição. Porto Alegre: Ed. Bookman, 2001.

IANSITI, Marco; LAHKHANI, Marim R. A Era da inteligência Artificial. 1ª ed. Cascavel-PR: Ed. AlfaCon, 2021.

KURZWEIL, Raymond. The age of Intelligent Machines. MIT Press, USA, 1990.

LUGER, George F. Inteligência Artificial. 6ª ed. São Paulo: Pearson Education do Brasil, 2013.

MITCHELL, T. M. Machine Learning. New York: Ed. McGraw-Hill Science, 1997.

NORVIG, Peter.; RUSSEL, Stuart J. Inteligência Artificial. 3ª ed. Rio de Janeiro: Ed. Elsevier, 2013.

RICH, Elaine; KNIGHT, Kavin. Artificial Intelligence. McGraw-Hill Higher Education, USA, 1990.

RUSSELL, Bertrand. Fundamentos da Filosofia. 1ª ed. Barcelona (Espanha): Debolsillo, 2009.

RUSSELL, Bertrand. Os Problemas da Filosofia. 1ª ed. Lisboa (Portugal): Edições70, 2016.

SZWARCFITER, Jayme L. Teoria computacional dos Grafos. 1ª edição. Rio de Janeiro: Elsevier, 2018.

TURBAN, Efraim; VOLONINO, Linda. Tecnologia da informação para a gestão: em busca do melhor desempenho estratégico e operacional. 8ª ed. Porto Alegre: Ed. Bookman, 2013.

VALLE, R.; OLIVEIRA, S.B. Análise e modelagem de processos de negócio: foco na notação BPMN (*Business Process Modeling Notation*). São Paulo: Atlas, 2009.