

Jorge Balsan

Mestre em Engenharia de Produção - UFSC
E-mail: balsan@hotmail.com – Celular: (41) 99991-8313
Endereço: Av. Prefeito Lotário Meissner, 632 – Campus III, Jardim Botânico
CEP: 80210-170 – Curitiba/PR - (Brasil)

Adriana Maria Miguel Peixe

Doutoranda em Gestão da Informação - UFPR
E-mail: ammp5196@gmail.com – Celular: (49) 999-379513
Endereço: Av. Prefeito Lotário Meissner, 632 – Campus III, Jardim Botânico
CEP: 80210-170 – Curitiba/PR - (Brasil)

Adriana Berno

Mestranda em Desenvolvimento Econômico - UFPR
E-mail: adriana.berno76@gmail.com – Celular: (41) 99625-9413
Endereço: Av. Prefeito Lotário Meissner, 632 – Campus III, Jardim Botânico
CEP: 80210-170 – Curitiba/PR - (Brasil)

Jose Simão de Paula Pinto

Dr. em medicina, com foco em informática aplicada ao ensino e pesquisa em cirurgia
E-mail: simao@ufpr.br – Celular: (41)
Endereço: Av. Prefeito Lotário Meissner, 632 – Campus III, Jardim Botânico
CEP: 80210-170 – Curitiba/PR - (Brasil)

IOT MACHINE LEARNING

RESUMO

O conceito da *Internet* das Coisas (*IoT*), foi evidenciado por estudiosos de todo o mundo como um grande avanço na década passada e infere-se que muitos mais avanços estão por vir no presente e futuro próximo.

O estudo teve como objetivo explicar qual a importância da *Iot Machine Learning* na atualidade e futuro próximo e distante. Como metodologia utilizou-se no estudo em questão, natureza descritiva e exploratório quanto aos procedimentos, a qual caracteriza-se como uma pesquisa documental, bibliográfica e estudo de caso. E quanto ao problema de pesquisa, qualitativa. A *IOT* exige que os dados representem serviços melhores para os usuários ou aprimorem o desempenho da estrutura de *Internet of Things* a realizar isso de maneira inteligente. Dessa maneira, os sistemas devem poder acessar dados brutos de diferentes recursos por meio da rede e analisar essas informações para extrair conhecimento. E levando em conta os sucessos recentes no *machine learning* em vários domínios, infere-se que não se precisa de novos algoritmos, mas muitos dados de exemplo e poder computacional suficiente para executar os algoritmos. Em uma infraestrutura de *IoT*, bilhões de dispositivos eletrônicos

estão conectados à *Internet* e esses dispositivos são equipados com sensores que observam ou monitoram vários aspectos da vida humana no mundo real para apoiar mais serviços onipresentes e inteligentes. Um ecossistema de *IoT* moderno envolve a rede entre dispositivos físicos e componentes cibernéticos, bem como as interações sociais deles.

Palavras-chave: *Iot Machine Learning. Iot. Machine Learning*

ABSTRACT

The concept of the Internet of Things (IoT), was evidenced by scholars from all over the world as a great advance in the past decade and it is inferred that many more advances are to come in the present and near future. The study aimed to explain the importance of Iot Machine Learning in the present and in the near and distant future. As a methodology, it was used in the study in question a descriptive and exploratory nature regarding the procedures, it is characterized as a documentary, bibliographic research and case study. What about the qualitative research problem. According to Yin, the case study is: "one of the most challenging endeavors in research" (YIN, 2010, p. 23). The IOT requires that data represent better services for users or improve the performance of the Internet of Things structure to do this intelligently. In this way, systems must be able to access raw data from different resources through the network and analyze this information to extract knowledge. And taking into account the recent successes in machine learning in several domains, it appears that you do not need new algorithms, but a lot of example data and enough computational power to execute the algorithms. In an IoT infrastructure, billions of electronic devices are connected to the Internet and these devices are equipped with sensors that observe or monitor various aspects of human life in the real world to support more ubiquitous and intelligent services. A modern IoT ecosystem involves the network between physical devices and cybernetic components, as well as their social interactions.

Key-words: *Iot Machine Learning. Iot. Machine Learning.*

1. INTRODUÇÃO

O termo "*Internet das Coisas*" (*IoT*) é usado como uma palavra-chave que abrange vários aspectos relacionados à extensão da *Internet* e da *Web* e do domínio físico, por meio da implantação generalizada de dispositivos distribuídos espacialmente com identificação, detecção e / ou capacidade de atuação (MIORANDI et. al., 2012; JAYASINGHE et. al.,2019).

Segundo Evans (2011, p.3) o termo *IoT* teria surgido em 2008. De lá para cá a evolução é enorme e já em 2016 Hu (2016, p.5) previa 28 bilhões de dispositivos conectados em 2020. Estudos recentes (2019) da Cisco *Networks* colocam um número de 31 bilhões de dispositivos conectados no ano de 2020 e preveem 75 bilhões no ano de 2025. A união internacional de telecomunicações cita a questão de comunicação como sendo essencial à economia moderna, colocando três modalidades em expansão: comunicação entre humanos (H2H - Human to Human); entre humanos e coisas (H2T - Human to Things); e,

dentre as próprias coisas entre si (T2T - Things to Things), visando comunicação de dados com quaisquer coisas em quaisquer lugares e a qualquer tempo ITU (2005, p.13). Obviamente a enorme quantidade de dados derivada desta última leva à necessidade de sua análise e utilização, evidenciando-se a questão do aprendizado de máquina.

As interações de coisas x coisas e de humanos com coisas criam novas oportunidades de negócios, inclusive intensificou-se nesta época de Pandemia *Coronavirus Disease 2019* - (COVID-19). A COVID-19 vem a ser uma doença infecciosa causada pelo coronavírus da síndrome respiratória aguda grave 2 (SARS-CoV-2). Onde tem-se buscado reunir estudos que relacionem pesquisa e desenvolvimento sobre os impactos e efeitos comunicação na contemporaneidade em todas as suas esferas. Os diálogos entre comunicação, tecnologia e comportamento (individual ou coletivo) no âmbito educacional, jurídico, social, cultural, econômico, político e demais áreas torna-se fundamental neste momento.

Seja a partir da evolução dos protótipos e soluções criadas, por meio da evolução do *feedback* de baixa para alta fidelidade ou pela oportunidade para *lean startups* que façam uso dos dados gerados (McELROY, 2016, p.15). Destaca-se aqui a necessidade de controle e de ética no uso dos dados, preocupação que, acompanhando questões mundiais, deu origem no Brasil à Lei Geral de Proteção de Dados, LGPD - que passou a vigorar a partir de 18 de setembro de 2020, pelo presidente Jair Bolsonaro a “Medida Provisória 959”, que tratava do prazo da Lei Geral de Proteção de Dados Pessoais (LGPD). Como o Senado havia determinado vigência imediata, a lei começou a valer já em 2020 e não como se esperava 2021 passar a vigorar.

A LGPD tem como intuito integrar as regras sobre tratamento de dados pessoais de clientes e usuários por parte de empresas públicas e privadas. A ideia é simplificar a vida dos cidadãos e facilitar a fiscalização contra abusos na utilização desses dados garantindo maior segurança e governança decorrentes do crescimento dos dispositivos e o número cada vez maior de ativos organizacionais habilitados para *IoT*. (CONJUR, 2020). Entre os desafios que a *IoT* coloca para as organizações estão os problemas de segurança e governança (MEIDAN, et al., 2017).

As automações e inovações constantes estão surgindo e permeando a vida das pessoas, possibilitando novos cenários e contextos. Estes equipamentos e *softwares* estão a cada dia gerando mais dados por meio de algoritmos simples e complexos. Para a mesma tarefa, pode haver vários algoritmos, alguns sugeridos pelo *machine learning* e pode-se estar interessado em encontrar o mais eficiente, exigindo o menor número de instruções ou memória ou ambos.

Nos dias de hoje o que falta em conhecimento, se compensa em dados. Em contrapartida, a tecnologia de dispositivos conectados à Internet, conhecida como *Internet of Things (IoT)*, continua estendendo a *Internet* atual, fornecendo conectividade e interações entre os mundos físico e cibernético. Além de gerar grandes dados caracterizados por sua velocidade em termos de dependência de tempo e localização com uma variedade de múltiplas modalidades e qualidade dos dados, descreve várias tecnologias e disciplinas de pesquisa que permitem que a *internet* alcance o mundo real dos objetos físicos. Tecnologias como comunicações sem fio de curto alcance, localização em tempo real e redes de sensores estão se tornando cada vez mais difundidas, tornando a *internet of things* uma realidade.

Diante deste contexto surge o problema de pesquisa: qual a importância da *IoT Machine Learning*?

O estudo teve como objetivo explicar qual a importância da *IoT Machine Learning* na atualidade e futuro próximo e distante.

Justifica-se o estudo pois um dos grandes impactos atuais está na substituição do trabalho humano por inteligência artificial, causando mudanças nas profissões e impulsionando o surgimento de algumas adaptações a outras. Tem-se estudos realizados por diversos autores nesta área, cita-se neste estudo pesquisa realizada em 2017, “*An IoT-Enabled Stroke Rehabilitation System Basedon Smart Wearable Armbandand Machine Learning*”, liderada por Yang et al., (2018) e “*ProfilIoT: A Machine Learning Approach for IoT Device Identification Basedon Network Traffic Analysis*, liderada por Meidan, et al., (2017).

Para Yang et. al., (2018) e Meidan et al., (2017) o grande impacto atual está em novas concepções para realizar as atividades pela inteligência artificial. Neste sentido não se deve pensar em perdas de mão de obra humana, mais em novas atividades e profissões que datam maior oportunidades com o aprendizado “inteligência artificial”. É política do governo e da sociedade em geral, estabelecer estruturas e atividades que facilitam o acesso ao novo conceito (BRISTOT et al., 2018). Na atualidade a *Iot* está ligada a sensores, automação, coleta e troca de informações, (JAYASINGHE et. al., 2019).

De acordo com Bastos (2015), às organizações virtuais descrevem um modelo organizacional baseado na Tecnologia da Informação (TI), normalmente essas organizações não possuem espaço nem recursos fisicamente alocados. Com esse surgimento, e seu acelerado desenvolvimento tecnológico, ocorreram mudanças de grande impacto no cenário corporativo, e conseqüentemente para a sociedade num todo. Para Meidan, et al., (2017), a segurança da *IoT* nas empresas está associada ao comportamento da própria organização, bem como a seus funcionários.

Este estudo está estruturado em quatro seções: a primeira retrata o quadro teórico para fundamentar o artigo. A seguir, tem-se a metodologia proposta para acessar os dados e analisá-los. A terceira seção analisa e discute o estudo de caso e por fim, têm-se as considerações finais e recomendações para pesquisas futuras.

2 RETRATO DO QUADRO TEÓRICO

Nesta abordagem do retrato do quadro teórico apresenta-se: *Iot Machine Learning; Internet Of Things; Deep Learning; Evolução; Tipos e Usos do Machine Learning; Requisitos para Criação de Bons Sistemas; Ramos do Machine Learning; Ferramentas do Machine Learning; Como Funciona Machine Learning; Benefícios X Limitações; Machine Learning e Iot na Bioinformática.*

2.1 IOT MACHINE LEARNING

De acordo com os ensinamentos de Mahdavinejah et. al., (2017) “*machine learning* é um subcampo da ciência da computação e é um tipo de inteligência artificial que fornece às máquinas a capacidade de aprender sem programação explícita”, ou seja, permite que os sistemas aprendam automaticamente e atualizem seus *softwares* sem ser explicitamente programados ou sem a intervenção humana. Se o sistema puder aprender e adaptar-se a essas mudanças, seu projetista não precisará prever e fornecer soluções para todas as situações possíveis. O *machine learning* também nos auxilia a encontrar soluções para eventuais

problemas de visão, reconhecimento de fala e robótica. O reconhecimento de faces, por exemplo, é uma tarefa que se efetua sem esforço; diariamente reconhecendo-se entes queridos olhando para seus rostos ou para suas fotografias, apesar das diferenças em postura, iluminação, estilo de cabelo entre outras características do ser humano. Mas se faz isso inconscientemente e não se consegue explicar quão intensamente. Como não se consegue explicar esses conhecimentos, não se pode minutar o programa de computador. Ao mesmo tempo, percebe-se que uma imagem de rosto não é apenas uma coleção aleatória de *pixels*; um rosto tem estrutura. É simétrico, há os olhos, o nariz, a boca, localizados em certos lugares da face.

Cada face da pessoa é um padrão composto por uma combinação particular dessas. Analisando amostras de imagens faciais de uma pessoa, um programa de aprendizado captura o padrão específico para essa pessoa e, em seguida, reconhece a verificação desse padrão em uma determinada imagem. Este é um exemplo de reconhecimento de padrões. O aprendizado avançado é o computador de programação que otimiza o desempenho de uma disciplina usando dados ou experiências anteriores. O papel da ciência da computação é duplo: primeiramente, no treinamento, precisa-se de algoritmos eficientes para resolver o problema de otimização, bem como para armazenar e processar a enorme quantidade de dados que geralmente se tem.

E em seguida, uma vez que um modelo é aprendido, sua representação e solução algorítmica para inferências também são eficientes. Em certas aplicações, a eficiência do algoritmo de aprendizagem ou inferência, ou seja, sua complexidade de espaço e tempo pode ser tão importante quanto sua precisão preditiva.

De acordo com Oliveira (2018), *IoT machine learning* consiste “no fato de que os artefatos ao seu entorno estão conectados à internet, agindo de modo perspicaz, aptos a executar e reger instrumentos por intermédio de informações designadas por uma rede”. Permite que objetos do dia-a-dia interajam entre si. Possibilita ainda o manejo e a leitura de sensores mesmo não se encontrando presente no mesmo ambiente, outro aspecto fundamental é o preço baixo dos sensores e placas, que permitem gerar um projeto com custo benefício excelente. Um grande número de dados são criados com os artefatos de *IoT*, produzem neste sentido modalidades diversificadas, com qualidade de dados variável definida por sua velocidade em termos de dependência de tempo e posição. Diante dessas perspectivas de emprego das inovações tecnológicas, pode-se concluir que os incentivos são muitos. É fundamental criar novos regimes de segurança, uma vez que a prevalência desses materiais estará condicionada na nuvem. Além disso, em alguns casos será necessária uma jurisprudência inerente para a usabilidade dos dados pessoais. Os profissionais que operam com tecnologia também terão que se habituar para atender e optar pela vasta demanda por automação. *Internet-of-Things (IoT)* refere-se a uma rede massivamente heterogênea formada por dispositivos inteligentes conectados à Internet e assim novas tecnologias surgiram.

2.2 INTERNET OF THINGS

É uma combinação de tecnologias incorporadas, a qual inclui comunicações com ou sem utilização de fio, dispositivos de sensores, atuadores e objetos físicos os quais são conectados à *internet*. Podendo também consistir em centenas de milhares de dispositivos

sensores cujo objetivo é operar em inúmeros tipos de ambientes. Mahdavinejad et al., (2017) explica que: A *IoT* exige que os dados representem serviços melhores para os usuários ou aprimorem o desempenho da estrutura de *IoT* para realizar isso de maneira inteligente. Dessa maneira, os sistemas devem poder acessar dados brutos de diferentes recursos por meio da rede e analisar essas informações para extrair conhecimento.

Os dispositivos *IOT* podem simular as necessidades de sensores, processadores e *chips* de comunicação de baixo custo, alto desempenho e economia de energia. Ela exige que os dados representem serviços melhores para os usuários ou aprimorem o desempenho da estrutura de *internet of things* para realizar isso de maneira inteligente. Os sistemas devem poder acessar dados brutos de diferentes recursos por meio da rede e analisar essas informações para extrair conhecimento. A *IOT* permite por exemplo que dispositivos físicos, veículos, edifícios, pontes e estradas recebam e permutem dados por intermédio de redes. Está relacionada principalmente a *IOT* aos setores automotivos (modais logísticos), aos bens de consumo e também a indústria. Entretanto, nos próximos anos, ela tem como “meta” reduzir a dependência de dispositivos de monitoramento por parte dos seres humanos, a qual irá acarretar em redução de erro humano. Os dispositivos de *internet of things* fornecerão diagnóstico e prevenção precoce de qualquer problema que fosse difícil de encontrar apenas com interação humana.

2.3 DEEP LEARNING

O *Deep Learning* consiste em um ramo mais amplo do *machine learning* tendo como base o aprendizado de representação de dados e trabalha com o funcionamento da rede neural artificial, a qual é utilizada em estudos do funcionamento do cérebro humano. Utiliza diversas camadas de processamento, sendo que cada uma usa a saída da camada anterior como uma espécie de entrada para si mesma. Este algoritmo pode ser também supervisionado ou não. O *deep learning* (*DL*) é desenvolvido principalmente para mapear complexos de entrada e saída. E tornou-se possível a implementação prática de diversas aplicações de *machine learning*. Segundo Lecun (2015), o *deep learning* descobre uma estrutura complexa em grandes conjuntos de dados usando o algoritmo de retro propagação para indicar como uma máquina deve alterar seus parâmetros internos que são usados para calcular a representação em cada camada da representação na camada anterior. Redes trouxeram avanços no processamento de imagens, vídeo, fala e áudio, enquanto redes recorrentes iluminaram dados sequenciais como texto e fala.

O *deep learning* auxilia com grande velocidade na resolução de problemas que até então não tinham solução. Infere-se que o *DL* é demasiadamente útil em aplicações, e conseqüentemente possui algumas vantagens como a eliminação de custos desnecessários detectando erros e defeitos no sistema; identificar e efetua a eliminação de falhas as quais torna-se difícil de detectar no sistema; efetua também a vistoria de anomalias: O *DL* pode inspecionar formas irregulares de difícil identificação por intermédio do *machine learning*.

2.4 EVOLUÇÃO

Grandes empresas de tecnologia estão despejando recursos e atenção para convencer o mundo de que a revolução da inteligência das máquinas está chegando agora resultando em produtos e serviços novos como carros autônomos, assistentes virtuais e muito mais. O *machine learning* evoluiu com o passar dos anos em virtude da sua capacidade de filtrar dados complexos. Muitos podem se surpreender ao saber que eles encontram aplicativos de aprendizado de máquina em suas vidas cotidianas por meio de serviços de *streaming* como o *Netflix* e algoritmos de mídia social que alertam para *trending topics* e *hashtags*. Em relação a esse contexto, Guy Caspi (2016) explana: Embora o *machine learning* tenha se tornado parte integrante do processamento de dados, uma das principais diferenças quando comparado ao aprendizado intenso é que ele requer intervenção manual na seleção de quais recursos processar, enquanto o aprendizado intenso o faz intuitivamente. Fazer a escolha certa sobre quais técnicas de *ML* devem ser usadas para um problema de negócios requer experiência e compreensão.

Por outro lado, a *internet of things* como um elo que conecta as coisas à *internet* utilizando essa conexão para fornecer algum tipo de monitoramento ou controle. E inúmeras indústrias estão encontrando novas formas de incorporar a *IoT* em sua infraestrutura. Steven Woo, (2019) e Jayasinghe et. al., (2019) evidenciam em seus estudos que à medida que a *IoT* evolui, a indústria deve desenvolver modos de lidar com a privacidade e segurança em virtude da vasta quantidade de dados aos quais são gerados por dispositivos conectados a uma rede.

Além de desenvolver tecnologia para lidar com essas questões, surge a dificuldade adicional de desenvolver soluções que atendam às necessidades de negócios dos mercados atendidos. A *Internet* das coisas atravessa fronteiras entre empresas e consumidores, complicando ainda mais as necessidades técnicas e de negócios de soluções que serão aceitas no mercado (GUY CASPI, 2016).

2.5 TIPOS E USOS DO MACHINE LEARNING

Elencar-se-á alguns exemplos de aplicações a respeito dos tipos e usos do *Machine Learning*: 1) Busca associações entre produtos comprados pelos clientes: se as pessoas que compram X normalmente também compram Y, e se há um cliente que compra X e não compra Y, ele ou ela é um potencial cliente Y. No caso de um *site* da *web*, os itens correspondem a *links* para páginas da *web*, e pode-se estimar os *links* que um usuário provavelmente clicará e usar-se-á essas informações para fazer o *download* dessas páginas com antecedência para acesso mais rápido; 2) A entrada e a saída são fornecidas ao computador juntamente com o *feedback* durante o treinamento. 3) Neste módulo, não existe fornecimento de treinamento aos computadores, fazendo com que as máquinas encontrem a saída por conta própria, um aprendizado não supervisionado. 4) Classificação: Crédito é uma quantia emprestada por uma instituição financeira a ser pago de volta com juros, geralmente em prestações. O intuito é inferir uma regra geral que codifique a associação entre os atributos de um cliente e seu risco. A regra é a extração de conhecimento, um modelo simples que explica os dados e, olhando para este modelo, temos uma explicação sobre o processo subjacente aos dados. Por exemplo, uma vez que aprende o discriminante separando os clientes de baixo risco e alto risco, tem-se o conhecimento das propriedades dos clientes de baixo risco. Pode-se usar essas informações para direcionar potenciais clientes de baixo risco

de maneira mais eficiente, por exemplo, por meio da publicidade. O *ML* também realiza a compactação ao ajustar uma regra aos dados; a compactação obtém uma explicação mais simples que os dados, exigindo menos memória para armazenar e menos computação para processar. Depois de ter as regras de adição, você não precisa se lembrar da soma de todos os possíveis pares de números. Outro uso do *machine learning* é a *outliers detection*, que está detectando instâncias que não obedecem a regra e são exceções. Nesse caso, depois de aprender a regra, não estamos interessados nela em si, mas nas exceções não cobertas por ela, o que pode implicar em anomalias que exigem uma atenção especial (como a fraude, por exemplo). 5) Suponha-se que é desejado obter um sistema que possa prever o preço de um carro usado. As entradas são os atributos do veículo (marca, ano, capacidade do motor, quilometragem, etc.) que se acredita afetar na variação do valor de um carro. A saída é o preço do carro. Tais problemas em que a saída é um número são problemas de regressão. Neste caso “X” indica os atributos do carro e “Y” indica ser o preço do carro. O *machine learning* ajusta uma função a esses dados para aprender Y como uma função de X.

Tanto a regressão quanto a classificação são problemas de aprendizado supervisionados onde há uma entrada “X” e uma saída, “Y”, cuja tarefa é aprender o mapeamento da entrada para a saída. Outro exemplo de regressão é a navegação de um carro autônomo, onde a entrada é fornecida por sensores no automóvel, câmera de vídeo, *GPS*, etc. E a saída é o ângulo pelo qual a roda de direção deve ser girada para avançar sem bater nos obstáculos e desviar da rota.

2.6 REQUISITOS PARA CRIAÇÃO DE BONS SISTEMAS

No momento em que é criado um sistema é necessário que sejam inclusos alguns itens para que esse sistema possa ser concluído com sucesso, os quais serão elencados a seguir: 1) Dados de entrada: São exemplos de unidades de entrada de um computador: microfone, teclado, mouse, scanner, leitor de código de barras, máquina fotográfica digital, *webcam*, *joystick* e outros acessórios de jogos. São exemplos de unidades de saída de um computador: monitor, caixas de som, impressora e outros. Os dados de entrada são necessários para prever a saída; 2) Algoritmos: uma sequência de passos para se executar uma função. Considerado como uma receita de bolo. Responsável pela padronização de dados; 3) Automação: O módulo em que se aplica a tecnologia para a otimização dos processos sejam industriais, comerciais, residenciais. Tem como objetivo de permitir que as máquinas operem automaticamente sem que seja necessária intervenção humana; 4) Iteração: Consiste no ato de repetição processual; 5) Escalabilidade: característica desejável em todo o sistema, rede ou processo, indicando a capacidade de manipular uma porção crescente de trabalho de forma uniforme, ou estar preparado para crescer. A capacidade de a máquina ser aumentada ou diminuída em tamanho e escala; 6) Modelagem: Criação de modelos de acordo com a demanda. Atividade de construir modelos que expliquem as características ou o comportamento de um *software* ou de um sistema de *software*.

2.7 RAMOS DO MACHINE LEARNING

Teoria da Aprendizagem Computacional: Subcampo do *machine learning* que estuda e analisa *algoritmos Adversarial Machine Learning*: Lida com a interação de *ML* e segurança de computador. Seu principal objetivo é procurar métodos mais seguros a fim de evitar qualquer forma de *spam* e *malware*. Seus princípios são: (1) encontrar vulnerabilidades em algoritmos de aprendizado de máquina; (2) idealizar estratégias para verificar estas vulnerabilidades potenciais; (3) executar estas medidas preventivas para melhorar a segurança dos algoritmos. Aprendizado de Máquina Quântica: Trabalha com a física quântica. Neste algoritmo, o conjunto de dados clássico é traduzido em computador quântico para processamento de informação quântica. Utiliza o algoritmo de busca de *Grover* para resolver problemas de pesquisa não estruturados; Análise Preditiva: Utiliza técnicas estatísticas de modelagem de dados, aprendizado de máquina e mineração de dados para analisar dados atuais e históricos para prever o futuro. Ele extrai informações dos dados fornecidos; *Robot Learning*: Lida com a interação de aprendizado de máquina e robótica. Ele emprega técnicas para fazer com que os robôs se adaptem ao ambiente circundante por intermédio de algoritmos de aprendizado; Indução de Gramática: Processo de o qual auxilia o aprendizado de gramática formal a partir de um conjunto de observações para identificar características do modelo observado. A importância do estudo da linguagem regular na área da computação deve-se, ainda, ao fato deste poder construir novas linguagens, provar propriedades e construir algoritmos. Ademais, existem vários tipos de *software* diferentes que utilizam as linguagens regulares, sendo o analisador léxico e os editores de texto os mais importantes a serem mencionados, (MENEZES, 2011; FURTADO, 2002).

Pode ser efetuado por meio de algoritmos genéticos e algoritmos gulosos. *Meta-Learning*: Neste processo são aplicados em meta-dados e lida principalmente com algoritmos de aprendizagem automática.

Os algoritmos gulosos tomam decisões com base apenas na informação disponível, sem se preocupar com os efeitos futuros de tais decisões, nunca reconsideram as decisões tomadas, independentemente das consequências. Não existe, portanto, necessidade de avaliar as alternativas nem de empregar procedimentos elaborados permitindo que decisões anteriores sejam desfeitas. O Método Guloso é um dos algoritmos mais simples que pode ser aplicado a uma grande variedade de problemas, que na maioria possuem “n” entradas e é necessário obter um subconjunto que satisfaça alguma restrição. Devido a tais características, de forma geral eles são fáceis de se “inventar” e implementar, e são eficientes quando funcionam (BRASSARD; BRATLEY, 1995; CORMEN, et al., 2002).

O Algoritmo Genético para Holland, (1975); De Jong, (1975) representa uma classe de algoritmos de otimização que empregam mecanismo de pesquisa probabilístico de soluções, baseado no processo de evolução biológico, combinando aspectos da mecânica da genética e da seleção natural de indivíduos. São uma classe particular de algoritmos evolutivos que usam técnicas inspiradas pela biologia evolutiva como hereditariedade, mutação, seleção natural e recombinação

2.8 FERRAMENTAS DO *MACHINE LEARNING*

Ferramentas do *machine learning* são aquelas que fornecem *kit* de desenvolvimento de *software* para desenvolvedores para implementar inteligência artificial em um aplicativo. Possui um *framework* e editor livre e de código aberto para construir sistemas inteligentes com o conceito de ontologia. Permite que os desenvolvedores criem, carreguem e compartilhem aplicativos. São sistema de resposta a perguntas de API aberta que responde a perguntas feitas em linguagem natural. As ferramentas do *machine learning* possuem uma coleção de ferramentas que podem ser usadas por desenvolvedores e também usadas nos negócios. Possuem como objetivo localizar erros, e corrigir pontos fracos no código. Efetuado por meio da automação. Caracteriza-se então as ferramentas do *machine learning* como uma biblioteca de *software* de código aberto para aprendizado de máquina. Fornecem uma biblioteca de cálculos numéricos, juntamente com documentação, tutoriais e outros recursos para suporte. Efetua lançamento de kits de ferramentas para desenvolvedores, juntamente com aplicativos que variam de interpretação de imagem a reconhecimento facial. Caracteriza-se como uma biblioteca de código aberto de alto desempenho utilizado em análises avançadas e é escrita em linguagem de programação C ++. Implementa redes neurais. Possui inúmeros tutoriais e documentações, além de uma ferramenta avançada conhecida como *Neural Designer*. É uma estrutura para processamento de dados em grande escala. Fornece uma ferramenta de programação para aprendizado profundo em várias máquinas. Usa-se em várias aplicações industriais na área da fala, visão e expressão. É outra plataforma de aprendizagem profunda escrita em linguagem C ++ e faz uso da linguagem *python* para interação entre os nós.

2.9 COMO FUNCIONA *MACHINE LEARNING*?

De acordo com Sharma (2018): o *machine learning* é apenas matemática ou jogo de números. Algoritmos funcionam entendendo este jogo que sublinha todos os algoritmos. Não há sabores ou gosto em algoritmos, mas simplesmente diferentes métodos para fazer o mesmo trabalho. Todo o tempo começa com a aprendizagem de uma função de destino.

Jason Brownlee (2011) explica que os algoritmos de *ML* são retratados em termos da função alvo “F” a qual mapeia a variável de entrada “X” para uma variável de saída “Y”. A fórmula a qual representa essa variável é:

$$y = f(x)$$

Há também um equívoco o qual é o independentemente da variável dessa entrada x. Logo, a fórmula ficará generalizada da seguinte forma:

$$y = f(x) + e$$

O mapeamento de x para y é realizado para previsões. Esse método é chamado de “modelagem preditiva”, a qual é utilizada para fins de realizar previsões com maior precisão. Em relação à *Internet of Things*, Jay Malhotra (2019), menciona que para muitos é bastante confuso como um sistema *IoT* realmente funciona. E assim como qualquer outro sistema possui etapas e componentes predefinidos para fazê-lo funcionar, a *IoT* também tem o seu sistema próprio o qual é composto de quatro componentes distintos que trabalham juntos para fornecer a saída desejada: (1) Sensores: Coletam dados muito pequenos do ambiente circundante que podem ser tão simples quanto uma localização geográfica ou tão complexos quanto os essenciais de saúde de um paciente. (2) Conectividade: Após os dados serem

coletados, eles são enviados para uma infraestrutura de nuvem, também conhecida como plataforma de *IoT*. (3) Processamento de dados: Depois que os dados chegam à infraestrutura da nuvem, eles são armazenados, analisados e processados com segurança usando um Mecanismo de *Big Data Analytics* para melhor tomada de decisões. Os dados processados são usados para executar ações inteligentes e imediatas que transformam nossos dispositivos físicos comuns em dispositivos excepcionalmente inteligentes. (4) *Interface* do usuário: Este notifica o usuário final sobre a ação via *e-mail*, texto, notificação ou som de alerta acionado em seu aplicativo *IoT*. Dependendo da complexidade do sistema *IoT*, o usuário pode deixar tanto a ação quanto o sistema serem executados automaticamente ou manualmente.

2.10 BENEFÍCIOS X LIMITAÇÕES *MACHINE LEARNING*

É um ramo da inteligência artificial fundamentado na ideia de que os sistemas podem aprender com análise dos dados. Em um mundo de desafios cada vez mais complexos, tudo depende do *ML*, método de análise de dados que automatiza a construção de modelos analíticos. Identificando padrões e tomando decisões com o mínimo de intervenção humana.

Mas, quais são os benefícios e limitações dessa tecnologia? Os benefícios são: 1) Tomada de decisões rápidas; 2) Capacidade de adaptação rápida ao novo ambiente, o qual muda rapidamente em virtude da atualização rápida dos dados; 3) Utiliza algoritmos avançados que auxiliam na melhoria da capacidade de tomada de decisões. 4) Ajuda na compreensão de padrões de dados exclusivos e com base nas ações e decisões que podem ser tomadas. 5) Fluxo do trabalho mais rápidos, contribuindo para o crescimento e aceleração dos negócios; 6) Qualidade do resultado será melhorada com menores chances de ocorrência de erros; 7) O *ML* pode filtrar e rejeitar inúmeras combinações possíveis permitindo pesquisadores aprimorarem soluções. 8) O *ML* pode desempenhar um papel de suma importância e relevância na manutenção e melhoria em comunidades rurais e urbanas como: Inspeção de usinas elétricas com auxílio de *drones*, mapeamento da poluição do ar e calibração de sensores de qualidade do ar de baixo custo. Apesar de seus inúmeros benefícios, (PINEDA, 2017) aponta limitações dessa tecnologia, bem como: 1) Diagnóstico e correção de erros: O problema com esse fato acaba sendo inevitável devido a erros, os quais diagnosticá-los e corrigi-los posteriormente pode ser uma tarefa complicada, pois isso exige que se passe pelas complexidades subjacentes de processos e algoritmos associados. 2) Restrições de tempo: É impossível fazer previsões precisas imediatas. E quanto maiores os dados e quanto mais tempo ele estiver exposto a esses dados, melhor será o desempenho. 3) Problemas com a verificação: Em situações que não estão incluídas nos dados históricos, será difícil provar com absoluta certeza que as previsões feitas por um sistema de aprendizado de máquina são adequadas em todos os cenários. 4) Limitações de previsões: As máquinas estão limitadas a responder indagações as quais são feitas as mesmas. Isto ocorre em virtude desses sistemas não compreenderem o contexto.

2.11 *MACHINE LEARNING* E *IOT* NA BIOINFORMÁTICA

Bioinformática é uma combinação de dois termos: “bio” + “informática”. Bio relacionado à biologia e informática à informação. Assim, a bioinformática é um campo que está envolvido com o processamento e a compreensão de dados biológicos utilizando a

abordagem computacional e estatística. Larrañaga et al., (2006) leciona que o *machine learning* possui várias aplicações na área de bioinformática as quais podem ser utilizadas nos seguintes subcampos: Genômica: Estudo do DNA dos organismos. Sistemas de *ML* podem auxiliar na localização de genes codificadores de proteínas em uma estrutura de DNA. A previsão gênica é realizada usando dois tipos de pesquisa denominados extrínsecos e intrínsecos. O *machine learning* é usado em problemas relacionados ao alinhamento do DNA. Proteômica: Estudo de proteínas e aminoácidos. É aplicada a problemas relacionados a proteínas, como predição de cadeias laterais de proteínas, modelagem de proteínas e predição de mapas de proteínas. *Microarrays*: São usados na coleta de dados sobre grandes materiais biológicos.

O *ML* pode auxiliar na análise de dados, predição de padrões e indução genética. Também pode ajudar a encontrar diversos tipos de câncer em genes. Biologia do Sistema: Trata da interação de componentes biológicos no sistema. Esses componentes podem ser DNA, RNA, proteínas e metabólitos. O *ML* ajuda na modelagem dessas interações. Mineração de texto: *Machine learning* ajuda na extração de conhecimento por meio de técnicas de processamento de linguagem natural. Em *IoT*, a bioinformática pode ser aplicada em doenças cardíacas, pois a mesma proporciona inúmeros modos em que os diagnósticos dessas enfermidades possam ser feitos bem como o tratamento das mesmas.

De acordo com Dos Santos e Albuquerque (2019): Se antes o médico tinha de esperar o paciente ir até ele para que fosse realizada a anamnese inicial, hoje podemos por meio de uma rede de monitoramento em tempo real, informar o *status* atual do paciente, como também prever situações extremas como um ataque cardíaco que pode em muitos casos levar a morte ou deixar sequelas que são onerosas tanto para a estrutura de tratamento da saúde e principalmente para o próprio paciente.

E ainda segundo os autores, “o DYHEARTMON – Monitoramento Dinâmico o Coração por ser uma ferramenta a qual tem a *IoT* como base será muito útil para apoiar tanto pacientes quanto profissionais de saúde os quais estão associados a enfermidades cardiovasculares”, (DOS SANTOS e ALBUQUERQUE, p.2, 2019).

3 METODOLOGIA

Para Jayasinghe et. al.; (2019) a escolha do método depende de um equilíbrio de vários fatores, como precisão, recursos computacionais, eficiência, disponibilidade de dados e urgência da situação em questão. O método de investigação utilizado é o indutivo, pois parte de uma premissa particular, dados e fatos constatados para uma premissa geral de conclusão. Gil (2017) menciona que, no raciocínio indutivo, não se deve buscar a generalização a priori, mas constatá-la e a partir da observação de casos concretos confirmados da realidade percebida o que se utiliza neste estudo.

O estudo em questão ainda possui natureza descritiva e exploratório quanto aos procedimentos, caracteriza-se como uma pesquisa documental, bibliográfica e estudo de caso. E quanto ao problema de pesquisa qualitativa. De acordo com Yin o estudo de caso é: “um dos empreendimentos mais desafiadores na pesquisa” (YIN, 2010, p. 23).

Sendo considerado um especialista de estudo de caso Robert Yin (2001, 2010,2016), uma das definições deste é que o estudo de caso é uma análise que investiga um fenômeno contemporâneo dentro de um contexto da vida real. Yin (2016) enfatiza em seus estudos, que

estudar o caso é a maneira mais adequada a ser utilizada quando é preciso responder a questões do tipo “como”, “qual” e “por que”. Nesse contexto corroborando ao questionamento neste estudo que vem a ser “qual” a importância da *IoT Machine Learning*? De acordo com Oliveira (2018), *IoT machine learning* consiste “no fato de que os artefatos ao seu entorno estão conectados à internet, agindo de modo perspicaz, aptos a executar e reger instrumentos por intermédio de informações designados por uma rede”. Permite que objetos do dia-a-dia interatuem entre si.

Conforme (Yin, 2010), o Estudo de Caso, como ferramenta de investigação científica é utilizado para compreender processos na complexidade social nas quais estes se manifestam: seja em situações problemáticas, para análise dos obstáculos, seja em situações bem-sucedidas, para avaliação de modelos exemplares.

O estudo de caso também é adequado quando se tem de lidar com uma grande variedade de problemas teóricos e descritivos. A aplicação deste método visa desenvolver um modelo compreensível, descrevendo padrões de comportamento que possibilitem a tomada de decisão sobre o objeto estudado ou a proposição de uma ação transformadora (COSTA et al., 2013).

4 ANALISAR E DISCUTE O ESTUDO DE CASO

O desenvolvimento para a evolução é inerente ao capitalismo, ambiente mutável, aumento da população, capital e sistema informação. Destaca-se deste modo que o capitalismo evolui e introduz-se novas concepções, novos métodos de produção ou transportes, mercado, organização industrial, fatores de competição nas firmas (SCHUMPETER, 1942). Nesta perspectiva Schumpeter tem a concepção que a tecnologia está dentro do sistema capitalista para o processo da gestão, evolução, tecnologia, e capital movida pelas entidades governamentais e empresas para se adaptarem ao meio e a sobrevivência.

Para tanto, neste aspecto *IoT Machine Learning; Internet Of Things; Deep Learning*; convergem para o mercado por meio da tecnologia, fontes de insumo e organização trazendo vantagens em custo, gestão da informação e qualidade em ampliar a verificação de dados, a organização produtiva empresarial e demais órgãos, sendo base da existência da gestão de informação e a evolução da firma. O aspecto microeconômico Schumpeter (1942) tem seus conceitos para a visão de grandes empresas na década de 30, para o desenvolvimento do país, os fatores são o processo de criar a tecnologia, atualmente a aprendizagem a *IoT Machine Learning*, ferramenta para a gestão da informação e novos conceitos de capital humano.

A preocupação das empresas e instituições governamentais e a gestão da informação, para verificar as condições de mercado estando associado a sobrevivência e a lucratividade de acordo Freeman (1982), desta forma busca a competitividade a estratégica para mudanças, a ação tecnologia, e a capacidade de se adaptar ao meio externo, a economia e política presente.

Para Godinho (1988) “a inovação não deve, contudo, ser concebida como um mero confronto entre as necessidades provenientes do mercado e as oportunidades tecnológicas geradas pelo sistema de ciência e tecnologia.” A capacidade de inovar de uma economia depende do respectivo sistema de inovação (Freeman, 1987), dos fatores ambientais que o condicionam e dos níveis de interação entre as diversas componentes desse sistema. De

acordo com Freeman (1987), pode-se descrever o sistema nacional de tecnologia. A organização e a eficácia do sistema de tecnologia condicionam simultaneamente o montante total, o tipo e o valor econômico gerado e ainda, este é um aspecto crucial, o ritmo a que essa tecnologia se difundem. No sistema de tecnologia entram em interação o sistema produtivo (ligado aos mercados de fatores primários, de *inputs* intermédios e de bens para consumo final), o sistema educacional (em particular o subsistema do ensino superior) e o sistema de ciência e tecnologia, destacando desta forma uma nova concepção, e novas oportunidade nas atividades do capital humano, apresentando uma nova forma de aprendizado a “inteligência artificial”. Entretanto, pode as estruturas governamentais, e a sociedade em geral, estabelecer a acessibilidade (BRISTOT et al., 2018).

Desta forma, a importância da Gestão da informação e o aprendizado a *lot machine Learning*, sendo a projeção da necessidade do aprendizado no mundo atual, a velocidade da acessibilidade às informações gera a importância da inteligência artificial no dia a dia das pessoas. A gestão da informação tem características interdisciplinar e multifacetado, compartilhando conceitos de diversas áreas de estudo, na concepção de modelos de gestão da informação voltados ao aprendizado organizacional (MONTEIRO; FALSARELLA, 2007), desta que o cerne a gestão da informação e o aprendizado a *lot machine Learning* são ferramentas necessárias para o dia a dia atual, cada dia, mas presente para as tarefas e atividades em vida em sociedade. Não se pode retroceder, a geração a *lot machine Learning* está presente na vida de todos, estando na atualidade no real e virtual.

Na concepção de Lévy, já está no presente e já é real, “A virtualização não é uma desrealização (a transformação de uma realidade num conjunto de possíveis), mas uma mutação de identidade, um deslocamento do centro de gravidade ontológico do objeto considerado...” (LÉVY, 1996, p.18). Segundo ele, "O virtual não se opõe ao real, mas sim ao atual. Sendo assim, infere-se que o virtual é real, reflexão do autor, onde evidencia que o aprendizado a *lot machine Learning* trará a gestão da informação e estando presente no mundo atual e virtual, simultaneamente, a inteligência artificial cada vez mais presente no mundo atual.

5. CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES PARA PESQUISAS FUTURAS

A *IOT* exige que os dados representem serviços melhores para os usuários ou aprimorem o desempenho da estrutura de *Internet of Things* a realizar isso de maneira inteligente. Dessa maneira, os sistemas devem poder acessar dados brutos de diferentes recursos por meio da rede e analisar essas informações para extrair conhecimento. E levando em conta os sucessos recentes no *machine learning* em vários domínios, infere-se que não se precisa de novos algoritmos, mas muitos dados de exemplo e poder computacional suficiente para executar os algoritmos. O estudo teve como objetivo explicar qual a importância da *Lot Machine Learning* na atualidade e futuro próximo e distante.

Pode-se idealizar que tarefas como tradução automática e até mesmo planejamento possam ser resolvidas com algoritmos de aprendizado relativamente simples, mas treinados em grandes quantidades de dados de exemplo, ou por meio de longas tentativas e erro. A inteligência parece não se originar de alguma fórmula estranha, mas sim do paciente, uso quase que de força bruta de um algoritmo simples e direto.

A mineração de dados é adotada para a aplicação de algoritmos de aprendizado de máquina a grandes quantidades de dados (WITTEN e FRANK, 2005; HAN e KAMBER, 2006). Na ciência da computação, costumava-se chamar a descoberta de “conhecimento em bancos de dados”. Pesquisas nessas diferentes comunidades (estatísticas, reconhecimento de padrões, redes neurais, processamento de sinais, controle, inteligência artificial e mineração de dados) seguiram caminhos diferentes no passado com diferentes fases.

Entretanto, insta salientar que a *internet of things* vem gradualmente trazendo inúmeras mudanças tecnológicas em nosso cotidiano, o que, por sua vez, ajuda a tornar nossa vida mais simples e confortável, apesar de várias tecnologias e aplicações.

Existe uma inumerável utilidade dos aplicativos de *IoT* em todos os domínios, incluindo médico, manufatura, industrial, transporte, educação, governança, mineração, habitat etc. Nos próximos anos, espera-se que a *IoT* interligue diversas tecnologias para permitir novos aplicativos, conectando objetos físicos em conjunto para apoiar a tomada de decisão inteligente.

REFERÊNCIAS

BARBOSA, J. P. Os três pilares da inovação – Machine Learning, Big Data e IoT, de 27 de dezembro de 2017. Disponível em: <http://igti.com.br/blog/ostres-pilares-da-inovacao-machine-learning-big-data-e-iot/> Acesso em: 19/06/2019.

BRASSARD, G.; BRATLEY, P. Fundamentals of Algorithmics. **Prentice Hall, Nova Iorque**, 1995. ISBN 01-333-5068-1.

BRISTOT, V. M.; GUIMARÃES FILHO, P. L.; GONÇALVES JUNIOR, A. C., FELISBERTO, R. S.; DEMO, P. A. de S. (2018). Industry 4.0 in Brazil. **International Journal of Development Research**, Vol. 08, Issue, 12, p.24803-24805, December 2018.

BROWNLEE, J. How Machine Learning Algorithms Work, de 11 de Março de 2011. Disponível em: <https://machinelearningmastery.com/how-machine-learningalgorithms-work/> Acesso em: 27/06/2019.

CASPI, G. The Evolution of Deep Learning and Machine Learning, de 09 de Dezembro de 2016. Disponível em: <https://www.itproportal.com/features/theevolution-of-deep-learning-and-machine-learning/> Acesso em: 28/06/2019.

CISCO NETWORKS, disponível em <https://www.cisco.com/c/en/us/solutions/internet-of-things/future-of-iot.html/> Acesso em: 27/04/2020.

COSTA, A. DE S.; NASCIMENTO, A. V. do; Cruz, E. B.; Terra, L. L.; Ramalho; Silva, M. The use of case study method in Information Science in Brazil. **InCID: R. Ci. Inf. e Doc.**, Ribeirão Preto, v. 4, n. 1, p. 49-69, jan. /jun, 2013.

CORMEN, T. H., LEISERSON, C. E., RIVEST, R. L., STEIN, C. **Algoritmos, teoria e pratica**. Editora Campus, Rio de Janeiro, 2002. ISBN 85-352-0926-3.

CONJUR. Disponível em <https://www.conjur.com.br/2020-set-18/sancao-governo-lgpd-comeca-valer-nesta-sexta> / Acesso em: 21/09/2020.

De JONG, K. “An analysis of the behavior of a class of genetic adaptive systems”. Tese de Doutorado, University of Michigan, USA, 1975.

DOS SANTOS, M. A. G., ALBUQUERQUE, V. H. C. de. Monitoramento Ambulatorial e Residencial Remoto da Pressão Arterial Baseado em Internet Das Coisas. In: CONCURSO DE TESES E DISSERTAÇÕES - SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 19. 2019, Niterói. **Anais** Estendidos do XIX Simpósio Brasileiro de Computação Aplicada à Saúde. Porto Alegre: Sociedade Brasileira de Computação, 2019.

EVANS, D. The internet of things. How the next evolution of the internet is changing everything. Cisco Internet Business Solutions Group (IBSG). April 2011. Disponível em: <http://www.cisco.com/c/dam/en_us/about/ac79/docs/innov/IoT_IBSG_0411FINAL.pdf>. Acesso em: 27/04/2020.

FREEMAN, C., The Economics of Industrial Innovation. Edition 2, Publisher F. Pinter, 1982.

FREEMAN, C. Technology policy and economic performance: lessons from Japan. London : Pinter, 1987.

FURTADO, O. J. V. Linguagens formais e compiladores. Universidade Federal de Santa Catarina: Departamento de Informática e de Estatística, p. 52, 2002.

GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2012.

GODINHO, M. M. **Inovação e difusão da inovação: conceitos e perspectivas fundamentais**. In: Capítulo 1 In: Rodrigues, M. J., Neves, A.; Godinho, M. M. (Org.). Para uma Política de Inovação em Portugal. Lisboa: Publicações Dom Quixote, 2003.

HAN, J.; KAMBER, M. **Data Mining Concepts and Techniques**, 2nd ed. San Francisco: Morgan Kaufmann, 2006.

HOLLAND, J. H. “**Adaptation in natural and artificial systems**”. The University of Michigan Press, Ann Arbor, 1975.

HU, F. (Org.) **Security and privacy in internet of things (IoTs). Models, algorithms, and implementations**. Boca Raton, FL: CRC Press, 2016.

ITU. International Telecommunication Union. ITU internet reports 2005: The internet of things. Executive summary. Switzerland, Geneva: International Telecommunications Union, November 2005. Disponível em: <https://www.itu.int/osg/spu/publications/internetofthings/InternetofThings_summary.pdf>. Acesso em: 27/04/2020.

JAYASINGHE, U.; LEE, G. M.; WON UM, T.; SHI, Q. Machine Learning Based Trust Computational Model For Iot Services. **IEEE transactions on sustainable computing**, v.4, no. 1, january-march 2019.

LARRAÑAGA, P. et al. Machine learning in bioinformatics, **Briefings in Bioinformatics**, Volume 7, Issue 1, March 2006.

LECUN, Y. et tal. Deep Learning, de 27 de maio de 2015. Disponível em: <https://www.nature.com/articles/nature14539> Acesso em: 19/06/2019.

LEVY, P. **O que é o virtual?** 2. ed. Trad. Paulo Neves. São Paulo: Editora 34, 1996. (Coleção TRANS).

LGPD disponível em < http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13709.htm/> Acesso em: 27/04/2020.

MAHDAVINEJAD, M. S. et al. Machine learning for internet of things data analysis: a survey, de 12 de Outubro de 2017. Disponível em: <[https://www.sciencedirect.com/science/article/pii/S235286481730247X#!](https://www.sciencedirect.com/science/article/pii/S235286481730247X#!>)> Acesso em: 19/06/2019

MEIDAN, Y.; BOHADANA, M.; SHABTAI, A.; GUARNIZO, J. D.; OCHOA, M. IN; TIPPENHAUER, N. O; ELOVICI, Y. Perfil IoT: A Machine Learning Approach for IoT Device Identification Based on Network Traffic Analysis. Department of Software and Information Systems Engineering, Ben-Gurion University, Beer-Sheva, Israel 2 Singapore University of Technology and Design, Singapore, 2017.

MENEZES, P. F. B. **Linguagens formais e autômatos.**6. ed. Porto Alegre: Bookman. p. 256, 2011.

MIORANDI, D; SICARI, S., DE PELLEGRINI, F.; CHLAMTAC, I. Internet of Things: Vision, Applications and Research Challenges. **AD HOC NETWORKS**, v.10 (7): P.1497–1516, 2012.

MALHOTRA, J. Internet of Things: What It Is, How It Works, Examples and More, de 19 de Novembro de 2018. Disponível em: <https://justcreative.com/2018/11/19/internet-of-things-explained/> Acesso em: 19/06/2019.

MONTEIRO, N. A.; FALSARELLA, O. M. Um modelo de gestão da informação para aprendizagem organizacional em projetos empresariais. **Perspectivas em Ciência da Informação**, Belo Horizonte, v. 12, n. 2, p. 81-97, 2007.

OLIVEIRA, N. IoT como fonte de dados para Machine Learning, de 7 de setembro de 2018. Disponível em: <https://medium.com/ensina-ai/iot-como-fonte-dedados-para-machine-learning-842b1b23c828> Acesso em: 19/09/2019.

PINEDA, M. E. Benefits and limitations of Machine Learning, de 9 de Setembro de 2017. Disponível em: <https://www.profolus.com/topics/benefitslimitations-of-machine-learning/> cesso em: 27/06/2019.

SHARMA, V. How Machine Learning Algorithms Works: An Overview, de 29 de Outubro de 2018. Disponível em: <https://vinodsblog.com/2018/10/29/howmachine-learning-algorithms-works-an-overview/> Acesso em: 27/06/2019.

SCHUMPETER, J. **Capitalism, Socialism e Democracy**. 1 ed. Harper USA. 1942.

WITTEN, I. H.; FRANK, E. **Data Mining Practical Machine Learning Tools and Techniques**, 2nd ed. San Francisco: Morgan Kaufmann, 2005.

WOO, S. Understanding the Evolution of the Internet of Things, de 11 de Outubro de 2016. Disponível em: <https://internetofthingsagenda.techtarget.com/blog/IoT-Agenda/Understanding-theevolution-of-the-internet-of-things> Acesso em: 28/06/2019.

YANG, G.; JIA DENG; PANG; G; ZHANG, H.; LI, J.; DENG, B.; PANG, Z.; XU, J.; JIANG, M.; LILJEBERG, P.; XIE, H.; YANG. H. IoT-Enabled Stroke Rehabilitation System Based on SWA and ML. **RehabilitationDevicesAnd Systems**, v.6, 2018.

YIN, R.K. **Pesquisa qualitativa do começo ao fim**. 2ª Nova Iorque: The Guilford Press. ISBN: v.978-1-4625-1797-8. 386, 2016.

YIN, R. K. Estudo de caso: planejamento e métodos. 4. ed. Porto Alegre: Bookman, 2010.

YIN, R. K **Estudo de caso: planejamento e métodos**. Editora ArtMeo. Porto Alegre, 2001.