

UNIVERSIDADE FEEVALE

JEFERSON KLAUS

RECRUTAMENTO E SELEÇÃO APOIADOS POR INTELIGÊNCIA ARTIFICIAL

Novo Hamburgo

2022

JEFERSON KLAUS

RECRUTAMENTO E SELEÇÃO APOIADOS POR INTELIGÊNCIA ARTIFICIAL

Trabalho de Conclusão de Curso apresentado
como requisito parcial à obtenção do grau de
Bacharel em Ciência da Computação pela
Universidade Feevale

Orientador: Prof. Dr. Rodrigo Rafael Goulart

Novo Hamburgo

2022

AGRADECIMENTOS

Gostaria de agradecer a todos os que, de alguma maneira, contribuíram para a realização desse trabalho de conclusão, em especial:

Aos meus pais, Milton e Regina, por sempre priorizarem meus estudos e incentivarem minha dedicação.

À minha esposa Angelica, e minhas filhas Sofia e Alice pela compreensão e auxílio durante todo o desenvolvimento deste trabalho.

Ao professor orientador Dr. Rodrigo, pela disposição e pelas sugestões concedidas durante a construção deste trabalho.

A todos que, de alguma forma, contribuíram para a conclusão deste trabalho.

Muito obrigado!

RESUMO

Uma das atribuições do Recursos Humanos é o recrutamento e seleção de novos integrantes à corporação, esta que constantemente vem evoluindo e tentando se adaptar as mudanças de mercado e à necessidade por mais eficiência. Contudo, eficiência na área de recrutamento também significa criatividade, pois, uma das etapas do recrutamento é a buscar por candidatos interessados na vaga e com perfis similares ao solicitado pelas contratantes. Desta forma, uma vaga publicada na internet, como por exemplo no LinkedIn, que tenha sucesso na captação de perfis, mesmo após um filtro inicial aplicado pelas plataformas de recrutamento, pode gerar um alto volume de candidaturas, que implica em um longo, desgastante e talvez estressante processo de triagem. Se o recrutador não for organizado não será eficaz no filtro de currículos, possibilitando que ótimos candidatos passem despercebidos pela etapa de triagem, ou que candidatos não aderentes à cultura da empresa sejam selecionados para próximas etapas, possibilitando assim, no final do processo contratos de curta duração. Com o surgimento da Inteligência Artificial (IA) veio a possibilidade de enriquecimento dos processos organizacionais, criando vantagens competitivas e gerando valor para as empresas, otimizando processos tais como o de recrutamento de novos integrantes, e trazendo vantagens para além das empresas, aos candidatos. Este trabalho tem como objetivo apresentar uma proposta de uso de Inteligência Artificial na geração de ranking de candidatos baseando-se na personalidade dos mesmos, utilizando para isto, técnicas de modelagem de elevação e algoritmos de Aprendizado de Máquina baseado em Árvores de Decisão, com intuito de melhorar a qualidade das contratações assim reduzindo taxa de rotatividade dos colaboradores. Além disso esta proposta demonstra em seus resultados que o tema permanece em aberto para novas pesquisas.

Palavras-chave: Inteligência artificial. Recrutamento e seleção. Treinamento. Eficácia.

ABSTRACT

One of the Human Resources attributions is the recruitment and selection of new members to the corporation, which is constantly evolving and trying to adapt to market changes and the need for more efficiency. However, efficiency in the recruitment area also means creativity, as one of the stages of recruitment is to search for candidates interested in the vacancy and with similar profiles to those requested by the contractors. In this way, a vacancy published on the internet, such as LinkedIn, that is successful in capturing profiles, even after an initial filter applied by recruitment platforms, can generate a high volume of applications, which implies a long, exhausting and perhaps a stressful screening process. If the recruiter is not organized it will not be effective in filtering resumes allowing great candidates to go unnoticed by the screening stage, or candidates who do not adhere to the company's culture to be selected for the next stages, thus allowing, at the end of the process, short-term contracts duration. With the emergence of Artificial Intelligence came the possibility of enriching organizational processes, creating competitive advantages and generating value for companies by optimizing processes such as the recruitment of new members, and bringing advantages beyond companies, to candidates. This work aims to present a proposal for the use of Artificial Intelligence in the generation of ranking of candidates based on their personality, using for this, elevation modeling techniques and Machine Learning algorithms based on Decision Trees, with the aim of to improve the quality of hiring, thus reducing the employee turnover rate. In addition, this proposal demonstrates in its results that the topic remains open for further research.

Keywords: Artificial intelligence. Recruitment and selection. Training. Efficiency.

LISTA DE FIGURAS

Figura 1 – Fases dos processos de recrutamento e seleção com intervenção de inteligência artificial (BOT).....	24
Figura 2 – Fases dos processos de recrutamento e seleção sem intervenção de inteligência artificial, forma tradicional.....	24
Figura 3 – Classes-alvo e classes de aprimoramento para problemas de rotatividade de funcionários	32
Figura 4 – Aumento de pedido de demissão voluntária	35
Figura 5 – Pipeline do Aprendizado de Máquina	36
Figura 6 – Curva de Qini	43

LISTA DE QUADROS

Quadro 1 – Métodos mais utilizados no processo de recrutamento externo	18
Quadro 2 – Estratégias de modelagem Uplift.....	30
Quadro 3 – Desempenho do classificador por característica operacional.....	30
Quadro 4 – Cenário hipotético de resultado de abordagem de retenção de colaboradores.....	33
Quadro 5 – Estrutura do <i>dataset</i> utilizado no experimento.	38
Quadro 6 – Correlação de tratamento e abandono do emprego	39
Quadro 7 – Divisão dos dados e correlação entre tratamento e variável	42
Quadro 8 – Matriz de confusão resultado de precisão	43
Quadro 9 – Coeficiente de Qini	44

LISTA DE SIGLAS

CA	Critérios de Avaliação
RH	Recursos Humanos
IA	Inteligência Artificial
TI	Tecnologia da Informação
RNA	Redes Neurais Artificiais
PLN	Processamento da Linguagem Natural
ETP	Employee Turnover Prediction
ETU	Employee Turnover Uplift
XGB	Extreme Gradient Boosting
GBT	Gradient Boosted Trees
RF	Random Forests
DT	Decision Tree

SUMÁRIO

1 INTRODUÇÃO	10
2 IDENTIFICAÇÃO DE PERSONALIDADE	14
2.1 RELAÇÃO ENTRE PERSONALIDADE E LINGUAGEM.....	15
2.2 BIG FIVE	15
3 GESTÃO DE PESSOAS	17
3.1 RECRUTAMENTO TRADICIONAL.....	17
3.2 SELEÇÃO TRADICIONAL	19
3.3 DIVERSIDADE E INCLUSÃO NO RH.....	19
4 INTELIGÊNCIA ARTIFICIAL NO RH	21
4.1 TRIAGEM DE CURRÍCULOS (<i>SCREENING</i>).....	25
4.2 RECURSO A CHATBOT	26
4.3 CONSTRUÇÃO DE UM MODELO DE CANDIDATO.....	26
4.4 GESTÃO DO PROCESSO DE SELEÇÃO (<i>SOURCING</i>)	26
4.5 GESTÃO ENTREVISTAS (<i>INTERVIEWING</i>).....	27
4.6 <i>SHORTLIST</i> DOS MELHORES CANDIDATOS	27
4.7 ADMISSÃO DIGITAL	27
4.8 RETENÇÃO DE COLABORADORES.....	28
5 PROPOSTA DE APLICAÇÃO DE IA NO APOIO A GERAÇÃO DO <i>SHORTLIST</i> A PARTIR DAS CARACTERÍSTICAS DE PERSONALIDADE	34
5.1 METODOLOGIA.....	35
5.1.1 Pré-processamento	39
5.1.2 Modelagem do aprendizado de máquina.....	40
5.1.3 Avaliação	40
5.3 RESULTADOS OBTIDOS.....	41
5.4 ANÁLISE DOS RESULTADOS	43
6 CONCLUSÃO	46
REFERÊNCIAS BIBLIOGRÁFICAS	48

1 INTRODUÇÃO

O mercado de trabalho sofre constantemente com mudanças abruptas, sejam elas mudanças econômicas, tecnológicas, políticas ou outras, e por esta razão existe a necessidade de uma adaptação rápida por parte de inúmeros setores das empresas.

Entre esses setores encontra-se o do Recursos Humanos (RH), onde uma das tarefas é o recrutamento e seleção, pois, a partir dela, são inseridos novos integrantes ao corpo de funcionários da empresa, cujo resultado pode alavancar o rumo dos negócios ou estagnar o mesmo.

De acordo com Chiavenato (2010) o RH, inicialmente chamado de Relações Industriais, surgiu por volta do século XX assumindo como principal atividade a mediação entre as organizações e as pessoas com o objetivo de minimizar conflitos existentes entre os objetivos das corporações e os objetivos dos colaboradores. Com o passar dos anos este setor foi adquirindo mais espaço dentro das organizações e agregando mais compromissos outrora inexistentes.

Constantemente novas profissões surgem e consigo requisitos cada vez mais complexos, e este é um dos fatores que continuamente torna o processo de seleção de novos integrantes cada vez mais demorado e custoso. A primeira etapa deste processo, após a divulgação das vagas existentes é a triagem de currículos, que uma vez divulgada na internet pode gerar um grande volume de candidaturas, implica em muito tempo despendido nesse processo até alcançar os candidatos com as competências desejadas. Contudo, além de ser um processo longo a triagem também pode ser extremamente desgastante para os recrutadores que precisam ter métodos para conseguir avaliar cada candidato, sem deixar passar currículos despercebidos (DE LIMA, 2019).

Vale destacar que o cansaço do recrutador após analisar um alto volume de informações, acaba impactando diretamente no julgamento. Por consequência, a contratação de um profissional que possui um perfil cultural não aderente ao da empresa pode ocasionar, após um período de prestação de serviço em um novo processo seletivo, gerando um retrabalho em contratação. As falhas no processo de recrutamento resultam não apenas em mais tempo despendido na sua correção como naturalmente exigem mais investimentos para o treinamento de novos integrantes após a contratação. Isso demonstra a importância de não somente as *hard skills*

(conhecimentos técnicos) serem compatíveis com as requisitadas para a vaga, mas, também um alinhamento cultural visando manter ou aumentar a eficiência e desempenho da equipe bem como contribuir para que a organização atinja seu objetivo em frente às exigências do mercado de trabalho. (DE LIMA, 2019).

Com o objetivo de simplificar e reduzir o tempo de um processo de recrutamento, inúmeras ferramentas são utilizadas para auxiliar nas tarefas, como por exemplo portais de recrutamento, redes sociais, sites com testes psicológicos e técnicos etc. Temos como exemplos os sites LinkedIn e Gupy. LinkedIn é uma rede social voltada a negócios onde os participantes podem expor seus currículos e interagir com outros profissionais e empresas. Gupy é uma Startup com foco em serviços de recrutamento e seleção, assim como processo de admissão. A empresa desenvolveu um produto que emprega IA nos processos de contratação.

Algumas ferramentas permitem centralizar todo o processo em um único lugar, possibilitando aos candidatos acompanharem o processo em “tempo real” e reduzindo a complexidade e papelada para os recrutadores. Um exemplo é o Pipefy, que possui um dashboard administrativo onde em uma única tela possui todos os candidatos organizados pela etapa que se encontram no processo de recrutamento, e ao mesmo tempo que a cada ação é aplicada a um cartão, que representa um candidato, este no mesmo momento, recebe um e-mail informando o status atual de sua candidatura. Contudo, mesmo que essas ferramentas auxiliem na redução de complexidade, tempo e custo, elas ainda não garantem que o resultado (candidato contratado) será eficaz, isto é, o desempenho do candidato quando contratado será o esperado pelo empregador e que este contrato será duradouro.

De acordo com Kumar (2017), um programa de retenção de funcionários pode ser uma solução eficaz para resolver a rotatividade dos colaboradores e reduzir os custos de rotatividade, aumentando significativamente a produtividade da empresa. Kumar (2017) também destaca que, várias estimativas sugerem que a não retenção de um gerente de nível médio pode custar para a organização até cinco vezes o seu salário. Além disso, os programas de retenção de funcionários podem aplicar várias estratégias para reduzir a rotatividade destes. Por exemplo, treinamento e desenvolvimento, promoção de equilíbrio entre vida profissional e pessoal e, claro, promoção de funcionários. Entretanto, aplicar o programa de retenção para todos os colaboradores pode ter um resultado pior do que não aplicar o programa em nenhum

deles, sendo assim, surge um novo problema: qual colaborador deve receber o programa de retenção.

Para o desenvolvimento desses processos que antecipam a movimentação de funcionários, evitando taxas de rotatividade que prejudiquem o negócio de uma organização, a análise dos dados pré-existente é fundamental. Simbeck (2019) destaca que esta análise está relacionada com as informações em Recursos Humanos em três níveis: **Descritivo**, primeiro nível de análise de RH, descreve as relações entre o atual e os dados históricos, por exemplo, o que causa a demissão de um funcionário. **Preditivo**, utiliza os dados atuais e históricos para prever resultados futuros e coletar informações significativas antes de ser usado para análises prescritivas, por exemplo, previsão de rotatividade de funcionários, isto é, identificar e prever possíveis colaboradores dispostos a de desligarem da empresa. **Prescritivo**, em contraste com a análise preditiva, a análise prescritiva está em um nível mais alto do que a análise preditiva, porque não é usada apenas para prever a rotatividade de funcionários, mas também opções de decisão para otimizar o resultado de processos, desde envio de e-mail marketing a tratando funcionários com alta taxa de rotatividade.

Para Kaufman (2019), a inteligência artificial (IA) é um campo do conhecimento ligado à linguagem, ao raciocínio, à inteligência, à aprendizagem e à resolução de problemas. Isto é, a IA pode ser utilizada em inúmeras áreas dentro das corporações como por exemplo no RH para fins de auxiliar nas tarefas mais complexas, armazenando e analisando uma grande quantidade de dados que ajudem na tomada de decisões, ou seja, com o uso dessa tecnologia o RH pode ser mais assertivo nas tarefas que antes não se imaginava sendo efetuadas por um computador.

Um exemplo de sucesso do uso da IA é o supercomputador cognitivo da IBM e seu software comercializado com o nome Interactive Care Insight for Oncology, popularmente mais conhecido como Watson Oncology, desenvolvido em parceria do centro de tratamento do câncer Memorial Sloan de Nova York. Em 2017 o Hospital do Câncer Mãe de Deus em Porto Alegre (RS), tornou-se o primeiro centro médico da América do Sul a utilizar este sistema, onde é capaz de analisar grandes quantidades de dados para apontar alternativas personalizadas e direcionar os dados pessoais de cada paciente com diagnóstico de câncer (WELCHEN, 2021).

A partir do momento que se compreende a importância do uso da IA em diversos setores e quão eficaz o seu uso pode ser para a solução de problemas, fica

claro que sua utilização pode ser aplicada para avaliar competências e atitudes de candidatos em situações reais, ajudando o recrutador a entender se existe compatibilidade entre a empresa e o candidato, e se este candidato tende a ter uma longa carreira na empresa, sem externar opinião pessoal. Portanto, o objetivo deste trabalho é identificar e analisar trabalhos científicos que tratam da relação entre contratações de baixa qualidade e sua influência na taxa de rotatividade de colaboradores. Dentre os trabalhos analisados foi identificado que o emprego de técnicas de IA podem auxiliar na geração de *shortlists* de candidatos, que são listas com os candidatos já filtrados por ordem de maior compatibilidade com o perfil que a organização procura contratar, e por sua vez afetam positivamente a permanência de colaboradores.

Este trabalho encontra-se dividido em seis capítulos. O primeiro capítulo corresponde à presente introdução, no segundo capítulo, é apresentada uma breve explicação sobre identificação de personalidade a partir de palavras utilizadas por indivíduos. Em seguida, no terceiro capítulo, é exposto como a gestão de pessoas tradicional funciona, com uma breve explicação na diferença entre recrutamento e seleção e a diversidade e inclusão no RH. No quarto capítulo é apresentada uma revisão de literatura sobre os principais conceitos sobre o uso da IA no processo de recrutamento e seleção e retenção de colaboradores, e do quinto ao sexto capítulo é apresentado uma proposta de solução de uso de IA para redução de taxa de rotatividade de colaboradores já aplicada no processo contratação de novos integrantes e as conclusões obtidos ao fim do desenvolvimento deste trabalho.

2 IDENTIFICAÇÃO DE PERSONALIDADE

Para responder à questão de pesquisa estabelecida, inicia-se a busca por evidências na literatura. Levando-se em consideração que existem várias abordagens atualmente no processo de recrutamento, a análise de personalidade é comumente menos utilizada do que as entrevistas de emprego.

De acordo com Jayaratne e Jayatilleke (2020), psicólogos organizacionais que há muito tempo formulam a hipótese de que a personalidade de uma pessoa está intimamente relacionada a seus desempenhos no trabalho, satisfação no trabalho e intenção de posse. E sugerem que o trabalho é mais prazeroso e, portanto, envolvente para o indivíduo e benéfico para o empregador e a sociedade em geral.

Inúmeros pesquisadores que estudaram a relação entre personalidade e carreira profissional, identificaram ou categorizam as personalidades de formas distintas. Uma das formas de conhecimento é a “personalidade prospectiva” que se refere a tendência consistente dos indivíduos de tomar iniciativas influenciando o ambiente ao redor.

Henning, Rangina e Dominik (2021), com o desenvolvimento da psicologia positiva, a influência de uma personalidade proativa no desempenho dos funcionários no trabalho tem atraído gradativamente a atenção de pesquisadores de áreas afins. Descobriu-se que uma personalidade proativa desempenha um papel importante no planejamento de carreira, desempenho no trabalho, satisfação no trabalho e realização de carreira. Como destacado pelos mesmos autores, identificaram que funcionários com personalidades proativas tendem a ser orientados para seu desenvolvimento futuro, e se esforçavam muito porque querem ser reconhecidos e ter um melhor relacionamento com seus colegas.

Na psicologia, a teoria baseada nos cinco grandes fatores (também conhecido como modelo OCEAN ou modelo Big Five) é o modelo mais amplamente aceito para descrever a estrutura básica da personalidade humana. Este modelo foi estudado pela primeira vez na década de 1990, quando cinco fatores ou traços de personalidade foram definidos e a partir daí são usados até os dias atuais. Todos os traços são geralmente examinados por meio de inventários de personalidade sendo o NEO Personality Inventory-3 o questionário padrão atual para o modelo Big Five (HENNING; RANGINA; DOMINIK, 2021).

A personalidade de uma pessoa tem uma influência direta em como ela fala e quais palavras ela usa, entretanto, definir e medir a personalidade é um esforço muito complexo, e pode levar ao menos 30 minutos para que cada teste individual seja concluído. A cada item adicional da pesquisa, os pesquisadores aumentam o risco de os participantes desistirem da pesquisa antes da conclusão. Isso pode inibir a incorporação de dados de personalidade nos contextos mencionados, embora forneça insight úteis (HENNING; RANGINA; DOMINIK, 2021).

2.1 RELAÇÃO ENTRE PERSONALIDADE E LINGUAGEM

Como apresentado por Madhura e Buddhi (2018), a maioria das primeiras pesquisas baseou-se na abordagem de vocabulário fechado, em que a contagem do número de palavras em categorias predefinidas era usada para identificar atributos de personalidade. Por exemplo o Léxico Linguistic Inquiry and Word Count (LIWC) na sua versão de 2007 inclui 64 categorias, como família, triste, saúde etc., ao mesmo tempo que a versão de 2015 possui 76 categorias. Uma palavra pode pertencer a uma ou mais categorias e a quantidade de palavras nessas categorias são usadas para classificar e analisar o uso da linguagem.

Correlações encontradas nos estudos utilizando a categorias de LIWC identificaram por exemplo que pessoas extrovertidas produzem textos menos complexos e utilizam mais palavras emocionais, sociais e positivas.

2.2 BIG FIVE

Um aspecto importante no contexto do modelo Big Five é a hipótese lexical, a qual afirma que as palavras podem servir como fonte de informações e ser usadas para definir os traços de personalidade de um indivíduo. Assim, palavras que carregam características importantes de um grupo de pessoas, passarão a fazer parte da linguagem desse grupo. Além disso, as diferenças mais relevantes provavelmente estão codificadas em uma única palavra. Isso implica que todas as palavras e frases relevantes para descrever importantes traços de personalidade já devem ser incorporadas na linguagem diária.

O Big Five, também conhecido como modelo de cinco fatores ou OCEAN, é uma das muitas implementações de perspectiva de traço e tem sido utilizado em muitos estudos. Este modelo unificou diferentes abordagens para descrever a personalidade com o menor número possível de traços, mais especificamente em cinco, que juntos formam a popular sigla OCEAN.

Abertura para experiência, consciência, extroversão, amabilidade e neuroticismo, ou em inglês como são mais conhecidos Openness, Conscientiousness, extraversion, agreeableness e neuroticism são os fatores que compõem este modelo, normalmente sendo abreviados para como já citado o termo OCEAN. O significado de cada traço no modelo Big Five é explicado por Henning, Rangina e Dominik (2021) como sendo: **Abertura** descreve o grau de abertura para novas experiências, alta **conscienciosidade** é representada por um senso de dever, disciplina e confiabilidade. Pessoas com alto grau de **extroversão** são tipicamente mais extrovertidas, falantes e enérgicas. Elas tendem a ter uma rede social maior. Um alto grau de **amabilidade** pode ser expresso por modéstia, confiabilidade e vontade de se comprometer. O **neuroticismo** é uma escala para a estabilidade emocional. Pessoas nervosas e ansiosas pontuam altos valores em neuroticismo.

3 GESTÃO DE PESSOAS

De acordo com Toledo (2003), a área dos Recursos Humanos (RH) é uma área que sempre esteve presente nas companhias, entretanto, inicialmente suas atividades se focavam na parte burocrática na contratação, sem ter nenhum reconhecimento no auxílio do desenvolvimento estratégico das companhias. Contudo, ao passar dos anos, as competências solicitadas aos candidatos foram se tornando avançadas e complexas, transformando assim os empregados em não mais apenas mão de obra de linha de produção e sim em ferramentas especializadas para alcançar metas e atingir objetivos.

As companhias atuais tendem a procurar formas inovadoras de gerenciar as pessoas, pois o ambiente organizacional está exigindo postura mais adequada de gestores no que diz respeito a estimular a harmonia das relações interpessoais dentro de uma empresa. Atanazio et al. (2021), destacam uma observação de Mello et al, (2012), que esta postura garante a eficiência e a eficácia interna na execução de tarefas, juntamente com a satisfação pessoal dos funcionários, pontos que levam ao sucesso do negócio (ATANAZIO, 2021).

3.1 RECRUTAMENTO TRADICIONAL

Como identificado por Sousa (2021), o recrutamento atua como um canal de descoberta de candidatos, tentando encontrar candidatos que mostrem interesse para o preenchimento das vagas existentes. É importante destacar que existem dois tipos de recrutamentos diferentes entre si. O recrutamento interno, que visa procurar o melhor colaborador dentro da própria organização, podendo ocorrer por transferência/troca de funções, promoção e/ou um misto de transferência e promoção, onde muitas das vezes se transforma numa grande desvantagem pois não existe entrada de novas ideias e experiências que são importantes para o processo de inovação. E o recrutamento externo, que é exatamente o oposto do interno, onde os candidatos são de fora da organização, e revela-se mais vantajoso na medida que entra novo capital intelectual.

Para a captação de profissionais externos existem alguns processos muito utilizados atualmente. Analisando estes listados no Quadro 1, nos dias atuais fica claro

sem a necessidade de um estudo aprofundado para compreender quais destes resultam em maior quantidade de candidatos para uma vaga, entretanto Sousa (2021), destaca isso citando como o recrutamento online, o que utiliza sites especializados para a captura de candidatos como por exemplo LinkedIn, como a principal fonte de informação para quem procura uma oportunidade.

Quadro 1 – Métodos mais utilizados no processo de recrutamento externo

Processo	Trecho retirado de Sousa (2021)
Anúncios em locais visíveis da empresa que sejam expostos ao exterior	“método muito importante tendo em conta que um candidato mais proativo é capaz de se dirigir à empresa demonstrando interesse na mesma, quer tenha vaga aberta ou não” (p. 18).
Organizações institucionais	“como escolas e universidades, locais que são um manancial de verdadeiro capital humano que está pronto e deseja o mais rapidamente possível entrar no mercado de trabalho;” (p. 18).
Anúncios em jornais e revistas	“um método bastante antigo e que continua a revelar os seus frutos pela facilidade de acesso ao público em geral;” (p. 19).
Consulta à base de dados	“consulta às bases de dados da própria empresa, onde podem existir candidatos com potencial que não ficaram colocados nos processos seletivos anteriores e que já estejam sinalizados ou se tenham candidatado espontaneamente, sem vaga aberta;” (p. 19).
Sindicatos e associações	“Através de contato com sindicatos e associações;” (p. 19).
Intercâmbio	“Intercâmbio entre empresas” (p. 19).
Agências de recrutamento	“Agências de recrutamento, que costumam ser contratadas por empresas que não têm propriamente um departamento responsável e que se debruce no processo de recrutamento especificamente. Acabam por ser utilizadas como outsourcing;” (p. 19).
Sites especializados	“Sites especializados na procura de emprego, site da própria organização e/ou redes sociais” (p. 19)

Fonte: elaborado pelo autor

Vale destacar que após esta etapa inicial de captação de candidatos, segue um novo processo até a conclusão da contratação, que inclui, análise de currículos, entrevista, testes de avaliação de conhecimentos específicos, dinâmicas em grupo, exame médico, fora procedimentos que empresas podem ter em particular, e tudo isso é um processo custoso e cansativo, sem falar que se pode ao final, não obter o resultado esperado (ATANAZIO, 2021).

3.2 SELEÇÃO TRADICIONAL

Como destacado por Sousa (2021), o processo de seleção tem duas finalidades básicas, sendo a primeira, selecionar um grupo de candidatos com as melhores competências para ocupar determinada vaga, a fim de encontrar o candidato que dê maior retorno para a empresa, e a segunda, tentar prever o futuro comportamento do candidato selecionado na posição a ocupar. Em suma a diferença entre recrutamento e seleção é, enquanto o recrutamento consiste na aplicação de um conjunto de técnicas e procedimentos para atrair candidatos qualificados, a seleção é o processo de escolher os mais adequados para cada vaga (LOPES, 2021).

Para que se possa efetuar o processo de seleção corretamente é necessário que se definam critérios, e que esteja bem claro e definido as políticas de seleção das organizações e dos cargos que se querem preencher (SOUSA, 2021). Alguns dos critérios a serem definidos podem ser: conhecimento que o candidato deve apresentar, experiência e aptidões necessárias e adequadas, características pessoais (paciência, iniciativa, sociabilidade etc.), local de residência, meio de transporte entre outros. Tendo todos os critérios bem definidos os recrutadores definem métodos que lhe auxiliarão para a identificação das particularidades pessoais de cada indivíduo, possibilitando a seleção dos mais aptos. Estes métodos podem ser a análise de currículos, e carta de apresentação, teste técnicos e psicológicos, em alguns casos testes de aptidão física, e entrevistas (SOUSA, 2021).

3.3 DIVERSIDADE E INCLUSÃO NO RH

A diversidade tem muitas características, incluindo histórico, idade, gênero, orientação sexual, raça, etnia, cultura, religião, geografia, deficiência, status socioeconômico, área de especialização, nível de experiência, estilo de pensamento e conjunto de habilidades. Como destacado por Atanzio (2021), os benefícios de incluir indivíduos com diferentes perspectivas do mundo, trazem um grande potencial para melhorar a capacidade de inovação das organizações.

Entretanto, conforme apresentado por Maccali et al. (2015), para que a gestão da diversidade seja efetiva, é necessário um alinhamento com os aspectos da política de recursos humanos da organização, alinhados com a diretoria que possibilite estas

ações de inclusão, assim como conseqüentemente, o surgimento de uma cultura de inclusão da diversidade, destacando as práticas de recrutamento, seleção, treinamento e cultura organizacional.

É possível notar cada vez mais empresas abrindo vagas inclusivas, e não por algum tipo de obrigação legal, mas, sim, como destacado por SWARTZ, (2019), os benefícios de incluir indivíduos que também são pensadores com diferentes visões de mundo trazem um grande potencial para aumentar a capacidade de inovação das organizações.

Ainda de acordo com Swartz (2019) inúmeras evidências sugerem que equipes que incluem diferentes tipos de pensadores superam grupos homogêneos em tarefas complexas, incluindo melhor resolução de problemas, maior inovação e previsões mais precisas. Sendo assim, equipes diversificadas apresentam um melhor desempenho quando encarregada de abordar um determinado problema.

4 INTELIGÊNCIA ARTIFICIAL NO RH

Lopes (2021), em sua revisão literária sobre Inteligência artificial (IA), explica que mudanças causadas pelas tecnologias digitais foram aquelas que, na segunda metade do século XX, mais profundo impacto tiveram na nossa sociedade. O surgimento da internet e das comunicações móveis trouxeram consigo a possibilidade de conectar incontáveis dispositivos nesta rede mundial, tornando o mundo completamente conectado, com milhões, talvez bilhões de dispositivos conectados e comunicando-se entre si. Entretanto é importante destacar que, conforme Lopes (2021), uma questão importante surgiu após o aparecimento dos primeiros computadores: poderá um computador vir a comportar-se, um dia, de forma inteligente, exibindo um comportamento semelhante ao que um ser humano exibiria em situação idêntica? Cientistas, engenheiros e filósofos tentando responder esta pergunta veem contribuindo para o desenvolvimento da área que foi nomeada como Inteligência Artificial.

Sousa (2021) destaca que não existe uma definição para o termo de inteligência artificial, pode-se perceber diferenças interessantes nas definições de John McCarthy (1965), onde define a inteligência artificial como uma ciência da Computação que visa fazer os computadores se comportarem e pensarem como humanos. Entretanto, se analisar uma definição mais atual, é possível perceber uma leve mudança na definição, mas, o conceito principal muito próximo do de McCarthy, como pode ser visto a definição de Rich e Knight, (1991), como a inteligência artificial sendo um estudo que dá aos computadores a capacidade de fazer coisas que os humanos no início faziam melhor.

Sendo assim, sua definição está ligada também ao seu tempo e campo de atuação, mas de forma geral se a IA refere-se a um campo da ciência mais amplo além da ciência da computação, também abrange a psicologia, filosofia, linguística, entre outras (LOPES, 2021). Apesar de existirem inúmeras definições para o conceito de IA, neste estudo será utilizada a definição que é uma tecnologia onde os computadores podem pensar, fazer, interagir e agir em diversas áreas tal como um ser humano e serem igualmente tão capazes como um, mas, onde erros, enviesamentos, custo e tempos de produção, entre outros fatores, sejam reduzidos e,

consequentemente, os processos organizacionais desenvolvam a sua eficiência e eficácia (FERREIRA 2020).

Entretanto, a IA ainda apresenta grandes limitações, como apresentado por Jarrahi (2018), onde cita que máquinas tendem a ser incapazes de capturar a lógica interna e os padrões subconscientes da instituição humana, por este motivo, é pouco provável que a IA consigo lidar com problemas humanos em áreas em que dependem de tomada de decisão não convencionais e criativas.

Consequentemente, para retirarem melhor proveito da IA, as empresas deverão compreender como poderão trabalhar em conjunto com os computadores para através da colaboração do homem com a máquina, obterem melhores resultados utilizando os pontos fortes de cada um.

Como destacado por Peng, Yun, Yingdong, Gancheng, Xiangping, Jun e Runsheng (2020), a tecnologia de mineração de texto pode descobrir, recuperar e extrair informações de um texto, o que geralmente é muito complicado para fazer manualmente. Por este motivo a mineração de texto combina tecnologias como Processamento da Linguagem Natural (PLN), Inteligência Artificial, recuperação de informações e mineração de dados. No início, a mineração de texto tinha como objetivo fornecer inteligência governamental à agências de segurança para detectar atividades terroristas e outras ameaças à segurança.

Com os avanços no aprendizado de máquina (*Machine Learning*), modelos preditivos foram desenvolvidos usando abordagens de vocabulário fechado para inferir a personalidade do uso da linguagem. A presença de certas palavras e categorias de palavras tem sido altamente preditiva dos tipos de personalidades e os pesquisadores conseguiram desenvolver modelos de aprendizado de máquina usando conteúdo de linguagem de blogs, ensaios, micro blogs, postagens de mídia social etc.

Atanazio (2021) afirma que a sociedade está passando pela quarta revolução industrial, era que apresenta diversos meios de desenvolvimento de tecnologias e mudanças radicais no mundo. As corporações estão tentando acompanhar essa transformação em ritmo constante, e a tecnologia e a inovação se tornam cada vez mais presentes e obrigatórios dentro das organizações, pois, desempenham um papel fundamental, sendo o instrumento facilitador que ajudará nos processos de gestão e solucionará os mais diversos problemas.

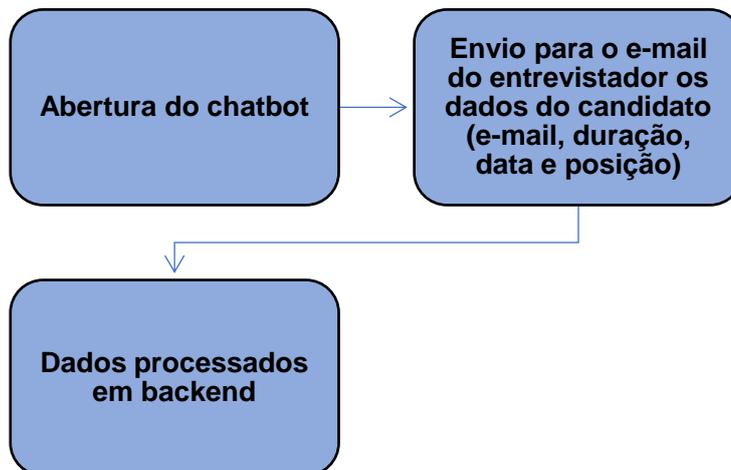
Hoje gestores que queiram posicionar estrategicamente as suas empresas para prosperarem num futuro pautado pela IA, devem estabelecer as seguintes metas: Utilizar a tecnologia para incrementar as competências humanas, reinventar os modelos operacionais; aproveitar a oportunidade de redefinir os empregos e repensar a conceção organizacional; e por fim, fazer os colaboradores seus parceiros na criação de uma empresa inteligente (Knickrehm, 2018, apud LOPES, 2021).

No âmbito dos processos de recrutamento e seleção, a IA assume um papel diferenciado, pois rompe com a ideia pré-concebida de que tem de haver profissionais especializados nestas dinâmicas e confere uma autoaprendizagem à máquina, capaz de analisar características comportamentais e fisiológicas (SOUSA, 2021), texto publicados em redes sociais para identificação de como é seu comportamento social (TADESSE, 2018), ou em respostas dadas para perguntas abertas feitas em entrevistas com objetivo de identificar características da personalidade do candidato (MADHURA; BUDDHI, 2018).

Diante deste fato, e de cada vez ser mais difícil identificar e atrair candidatos com competências exigidas, assim como, a competitividade entre organizações por talentos qualificados estar cada vez maior, tem-se percebido que por vezes os procedimentos atuais, sem o uso da IA, não se mostram eficazes na identificação das competências desejadas nos candidatos. Sendo assim, o uso da IA pode ser amplamente aplicado no processo de recrutamento, como já citado anteriormente, devido a seu leque de possibilidade e sua capacidade em tratar um enorme volume de dados, através de algoritmos, difere da limitada capacidade humana (LOPES, 2021), além de se destacar na redução de erros e tempo de resolução de problemas, maior produtividade e melhor aproveitamento da ação humana (SOUSA, 2021).

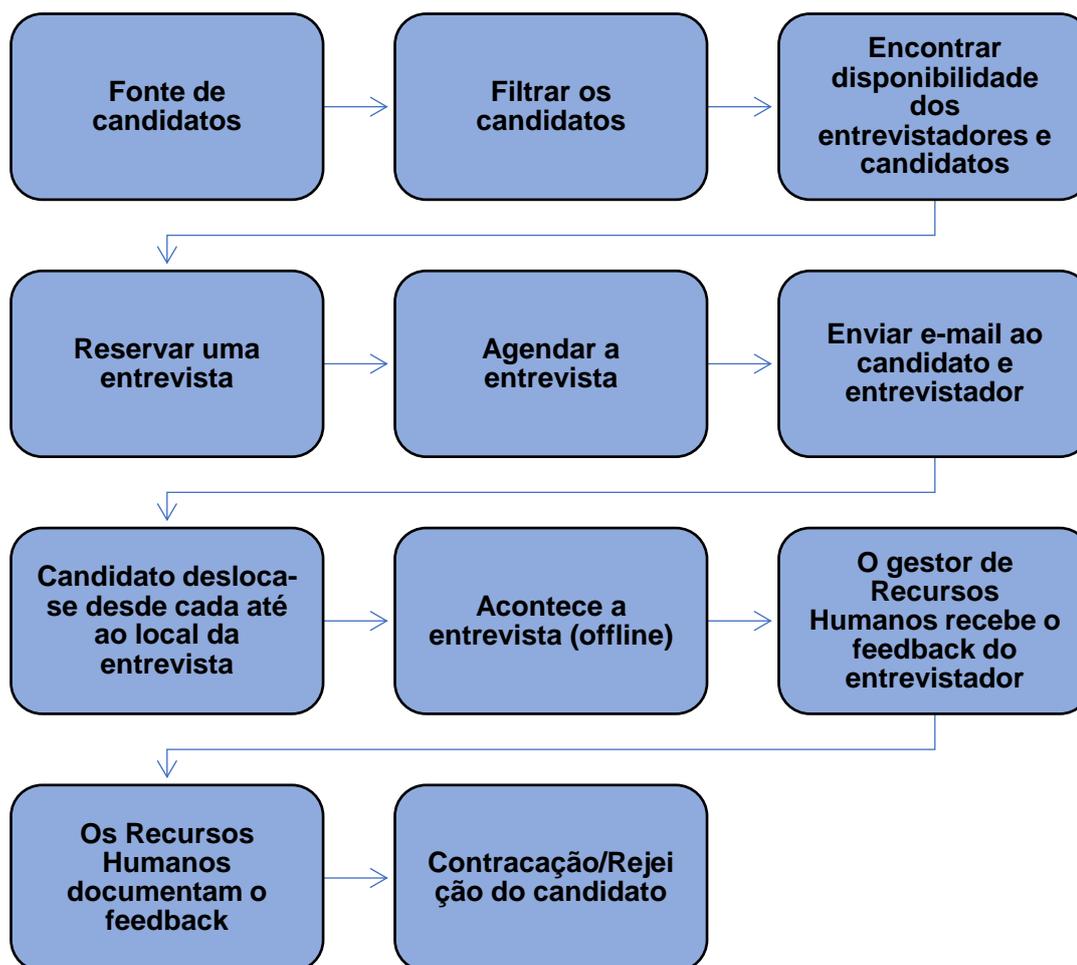
Para perceber de forma visual as diferenças entre os processos de recrutamento e seleção apoiados no uso da IA, e sem qualquer tipo de intervenção da IA, pode-se analisar os esquemas a seguir retirados do artigo elaborado por Souza (2021).

Figura 1 – Fases dos processos de recrutamento e seleção com intervenção de inteligência artificial (BOT)



Fonte: Sousa (2021, p.43)

Figura 2 – Fases dos processos de recrutamento e seleção sem intervenção de inteligência artificial, forma tradicional



Fonte: Sousa (2021, p.42)

Na Figura 1, é apresentado o esquema dos processos do recrutamento e seleção utilizando sistemas totalmente online e com a utilização de chatbot para a redução do esforço dos recrutadores em tarefas como: apresentação da empresa e das vagas ofertadas, agendamento de entrevistas, em alguns casos entrevistas propriamente e análise dos candidatos (conforme critérios previamente programados), em comparação na Figura 2, é exibido as fases dos processos de recrutamento e seleção, na forma tradicional, sem o uso da IA para auxiliar no processo, e na forma totalmente offline (SOUSA, 2021).

Um grande exemplo de empresa que adotou um processo apoiado no uso da IA para o recrutamento foi a Cargil do Brasil. Beier (2019) compartilhou a experiência na mídia relatando que a companhia compreende o foco na diversidade e inovação como único meio para alcançar e manter-se em alto nível competitivo. Por este motivo aplicou um procedimento de seleção às cegas sem qualquer meio de identificação de idade, gênero, cor ou características que possa ser tendenciosa com relações a pré-conceitos, e com auxílio da IA para filtrar os candidatos analisando se o que eles disseram em um vídeo gravado no início da candidatura se encaixava com os requisitos da vaga (ATANAZIO, 2021).

De acordo com Lopes (2021) a IA no recrutamento pode ter aplicabilidade em três momentos distintos: na triagem de currículos (*screening*), no recurso a *chatbot*, e na construção de um modelo de candidato. Já no processo de seleção, a IA pode ter aplicabilidade em quatro momentos distintos como: gestão do processo de seleção (*sourcing*), gestão de entrevistas (*interviewing*), *shortlist* dos melhores candidatos e admissão digital.

4.1 TRIAGEM DE CURRÍCULOS (*SCREENING*)

Na primeira etapa do processo de recrutamento, quando uma vaga é divulgada pela internet, pode gerar um grande volume de candidaturas que implica em muito tempo despendido nesse processo até alcançar os candidatos com as competências desejadas (DE LIMA, 2019). Porém com o uso da IA, a análise objetiva dos dados apresentados é assegurada, tendo como parâmetro o perfil definido para o preenchimento da vaga (LOPES, 2021). Esse perfil pode ser técnico, dependendo

apenas de uma análise dos conhecimentos apresentados, e/ou de personalidade, dependendo então de um processo para auxiliar a extração destas informações, como, por exemplo, uma série de perguntas abertas feitas no início do processo de candidatura para a extração das características da personalidade do candidato (MADHURA, 2020).

4.2 RECURSO A CHATBOT

A IA permite que os candidatos passem por uma experiência de interação com um assistente virtual, durante o processo de candidatura. Onde por meio dessa experiência possibilite o esclarecimento de dúvidas e uma agilização no processo (LOPES, 2021), de tal forma que durante a interação, é possível que a IA faça perguntas abertas ao candidato com o intuito de extrair informações que possam auxiliar no processo de recrutamento, como, por exemplo e já citado, características de personalidade do indivíduo (MADHURA, 2020).

4.3 CONSTRUÇÃO DE UM MODELO DE CANDIDATO

A IA permite a comparação dos resultados dos testes, avaliações e interações com *chatbots* durante o processo seletivo, possibilitando a identificação do candidato que melhor corresponda aos requisitos técnicos e comportamentais da vaga, assim, cruzando a todos os dados submetidos e criando um modelo de candidato ideal (LOPES, 2021).

4.4 GESTÃO DO PROCESSO DE SELEÇÃO (*SOURCING*)

A utilização da IA aumenta a eficácia na seleção de candidatos para vagas e reduz o tempo de triagem garantindo que os filtros aplicados sigam de acordo com a descrição da vaga a preencher, cruzando os requisitos das vagas fornecidos pela empresa contratante com a informação que consta nos currículos submetidos e aplica automaticamente um processo seletivo hierarquizando aos candidatos de acordo com as chances de serem contratados, comparando-os com o perfil procurado pela empresa (LOPES, 2021).

4.5 GESTÃO ENTREVISTAS (*INTERVIEWING*)

Entrevistas automatizadas permitem além de economizar tempo, também simplificar e melhorar o processo de seleção. Essa metodologia possibilita efetuar entrevistas iguais para todos os candidatos, isto é, efetuando as mesmas perguntas para todos, evitando assim o preconceito humano. Desta forma a IA irá assegurar que a escolha será baseada no mais qualificado ao invés de uma seleção com base nas melhores primeiras impressões (LOPES, 2021).

Um exemplo da aplicação da IA para entrevistas de emprego onde o cuidado com a diversidade é fortemente aplicado, é a chamada a entrevista às cegas, onde no processo de recrutamento e seleção, todos os dados sensíveis, fotos, nome, idade, gênero, classe social etc. são ocultos até as últimas etapas do processo, em que o candidato terá uma entrevista com o gestor. Até então, todo o processamento é feito por uso da IA, assim, o exemplo de gestão de entrevista se aplica na primeira entrevista onde o candidato envia um vídeo para a empresa, respondendo algumas perguntas estipuladas, ou responde um questionário com perguntas abertas, e a IA analisa esse material para obter informações do candidato e então efetuar a triagem e todas as etapas que se seguem (MADHURA, 2020).

4.6 *SHORTLIST* DOS MELHORES CANDIDATOS

A IA produz uma lista de candidatos por ordem de maior compatibilidade com o perfil que a organização procura contratar, mas para isso, são analisados os currículos dos candidatos, suas respostas nas entrevistas e os resultados de seus vários testes. Porém, no final, o peso da escolha será inteiramente da responsabilidade da inteligência humana (LOPES, 2021). Entretanto, como já visto, todo o processamento até esta etapa pode ser apoiado na IA, desde triagem e entrevista, até teste de personalidade e fit cultural, deixando apenas a última decisão para a inteligência humana.

4.7 ADMISSÃO DIGITAL

Por fim, a IA também permite efetuar a gestão contratual e documental de novos colaboradores no processo administrativo de admissão na empresa, de forma completamente digital, sendo assim empresas que possuem grande volume de admissão mensal podem deixar a cargo da IA gerir essas tarefas permitindo aos recrutadores e aos gestores concentrarem-se em outras tarefas que ainda não se aplica o uso da IA (LOPES, 2021).

4.8 RETENÇÃO DE COLABORADORES

As análises preditiva e prescritiva podem ser utilizadas para aplicar abordagens de Aprendizado de Máquina para prever e resolver muitos tipos de problemas que podem acontecer no futuro. Na aplicação de análise preditiva no RH, uma estratégia convencional de classificação binária como previsão de rotatividade de funcionários ou em inglês *Employee Turnover Prediction* (ETP) é frequentemente estudado na literatura para prever candidatos com propensão a abandono da empresa (ZHAO et al., 2018).

Por outro lado, Floris et al (2019) argumenta que a modelagem de elevação, ou em inglês *Uplift Model* tem um desempenho analítico melhor do que o modelo preditivo convencional para resolver problemas de rotatividade de funcionários. Wijaya et al. (2021) corrobora essa afirmação apresentando dados empíricos de uma comparação entre um modelo preditivo e um preditivo de elevação.

Originalmente aplicada a área de vendas, a modelagem *Uplift*, é um tipo de modelagem preditiva que visa prever o impacto de realizar algum tratamento (como uma ação de marketing direta) no comportamento de um indivíduo alvo. Isso facilita uma otimização da tomada de decisões em vários campos de aplicação (DEVRIENDT; MOLDOVAN; VERBEKE, 2018). Conforme destacado por Devriendt, Moldovan e Verbeke (2018), nos últimos anos, a modelagem *Uplift* atraiu um interesse crescente da comunidade científica, bem como de profissionais da indústria. E conforme explicitado em sua pesquisa e validado durante a busca por material literário, a maioria dos trabalhos propostos na literatura são no campo do marketing e vendas, onde a modelagem *Uplift* é aplicada para otimizar campanhas de marketing direcionadas em termos de clientes selecionados, bem como a abordagem da campanha. Do ponto de vista empresarial, a modelagem *Uplift* pode ajudar a alcançar

maiores taxas de vendas do que as técnicas preditivas tradicionais, levando a lucros maiores.

Esta modelagem usa o grupo de tratamento e controle selecionado aleatoriamente para medir a eficácia de um tratamento (KANE; LO; ZHENG, 2014). O grupo de tratamento representa os colaboradores que recebem algum tipo de ação de retenção (ex.: treinamento, promoção, troca de projeto etc) e o grupo de controle são aqueles não são incluídos nas ações de retenção. A proposta também emprega como uma das várias estratégias disponíveis a Lais Generalized Weighed Uplift (LGWUM) (Gubela et al., 2019), como apresentado no Quadro 2. Gubela et al. (2019), demonstra também que a estratégia LGWUM apresenta melhores resultados quando combinados com algoritmos baseados em árvore. Esta estratégia utiliza uma abordagem de quatro quadrantes, ilustrada na Figura 3, para medir a pontuação de elevação que será usada como resultado prescritivo para atingir os indivíduos certos com a ação planejada. Pontuação de elevação ou score de elevação é geralmente alguma forma de equação, ou seja, a probabilidade de um indivíduo responder favoravelmente, dado o tratamento, menos a probabilidade de um indivíduo responder favoravelmente, sem ser tratada (KANE; LO; ZHENG, 2014).

Um exemplo de algoritmo baseado em árvore é o Extreme Gradiente Boosting (XGB), proposto por Chen et al. em 2016 como um algoritmo de Aprendizado de Máquina baseado em Árvores de Decisão, onde suporta regressão e classificação. Este algoritmo é uma variante eficiente e escalável da Gradiente Boosting Machine (FRIEDMAN, 1999).

Zhoa (2018) apresentou um estudo comparativo sistemático de previsão de rotatividade, e com *datasets* de tamanhos distintos criando modelos de Aprendizado de Máquina utilizando vários algoritmos para identificar qual apresenta melhor performance de classificação em geral. Como pode ser verificado no Quadro 3, os algoritmos baseados em árvore (XGB, Gradient Boosting Trees (GBT), Random Forests (RF), Decision Tree (DT)) tem bons resultados de maneira geral, e foram considerados os quatro classificadores com melhor desempenho. Concluindo que o XGB teve o melhor desempenho em geral, e as árvores de aumento de gradiente ficaram em segundo lugar.

Portanto, Zhoa (2018) destaca que o algoritmo XGB obtém resultados satisfatórios na previsão de rotatividade de funcionários, sendo indicado como o algoritmo aplicado à modelagem Uplift do referente estudo.

Quadro 2 – Estratégias de modelagem Uplift

Category	Uplift modeling strategy	Acronym	Source
Basic	Two-Model Uplift Method	TWO_MODEL	Various
Advanced	Interaction Term Method	ITM	Lo ³³
	Treatment-Covariates Interactions Approach	TCIA	Tian <i>et al.</i> ³⁴
	Class Variable Transformation	CVT	Jaskowski and Jaroszewicz ³¹
	Lai's Weighted Uplift Method	LWUM	Lai <i>et al.</i> ⁴⁷
	Lai's Generalized Weighted Uplift Method	LGWUM	Kane <i>et al.</i> ²¹
Special	Reflective Uplift Modeling	REFLECTIVE	Shaar <i>et al.</i> ⁴⁶
	Pessimistic Uplift Modeling	PESSIMISTIC	Shaar <i>et al.</i> ⁴⁶

Fonte: Gubela et al. (2019, p.11)

Quadro 3 – Desempenho do classificador por característica operacional

Dataset	Median	Mean	STD	Min	Max
XGB	0.9462	0.9008	0.0847	0.7411	0.9862
GBT	0.9417	0.8960	0.0890	0.7408	0.9886
RF	0.9266	0.8771	0.0955	0.7397	0.9768
DT	0.8897	0.8412	0.1215	0.6289	0.9550
NN	0.8407	0.8234	0.0690	0.7268	0.9124
SVM	0.8096	0.7751	0.0935	0.5489	0.8571
LR	0.7543	0.7820	0.1062	0.6179	0.9500
LDA	0.7410	0.7473	0.0804	0.5875	0.8375
KNN	0.7373	0.7474	0.0543	0.6511	0.8117
NB	0.7160	0.7340	0.0698	0.6080	0.8333

Fonte: Zhoa. (2018, p.16)

Ao usar LGWUM como estratégia de elevação para obter a pontuação de elevação, aplicando uso deste para análise de candidatos, Wijaya et al. (2021) propõe que o grupo de teste e controle pode ser identificado com as mesmas características que são usadas quando o foco é retenção de colaboradores, como pode ser visto na Figura 3: **Grupo de Controle** (C), colaboradores que não foram tratados com um programa de retenção. **Grupo Tratado** (T), colaboradores que foram tratados com o programa de retenção.

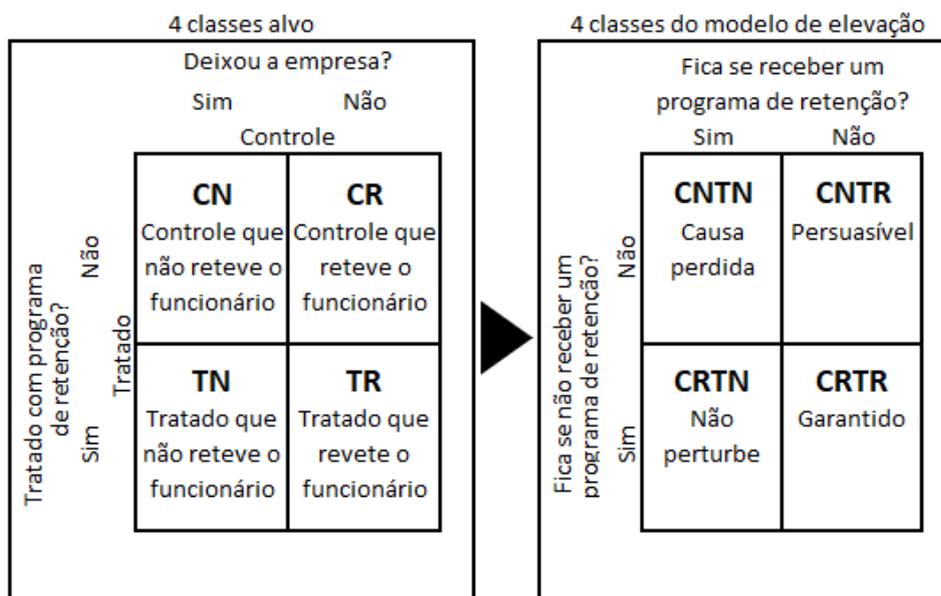
Wijaya et al. (2021) propõe, assim como outros autores que estudaram o uso da modelagem *Uplift* na abordagem de retenção de colaboradores, quatro classes alvo com base no status de tratamento e de rotatividade dos funcionários:

- **Controle que não reteve o funcionário (CN)**, representando os colaboradores que não foram tratados com programa de retenção e saíram da empresa,
- **Controle que reteve o funcionário (CR)**, representando os colaboradores que não foram tratados com o programa de retenção e ficaram na empresa,
- **Tratado que não reteve o funcionário (TN)**, que são os colaboradores que foram tratados com o programa de retenção, mas, deixaram a empresa e por último
- **Tratado que reteve o funcionário (TR)**, representando os colaboradores que foram tratados com o programa de retenção e permaneceram na empresa.

Portanto a combinação das classes iniciadas com a letra C com as classes iniciadas com a letra T, resultará em quatro classes teóricas de elevação também conhecidas como os quatro quadrantes. São elas:

- **Causas Perdidas (CNTN)**, colaboradores que tendem a sair da empresa sendo tratados ou não,
- **Persuasíveis (CNTR)**, colaboradores que tendem a ficar na empresa sem receberem algum tipo de tratamento,
- **Não Perturbe (CRTN)**, colaboradores que tendem a sair da empresa se forem tratados e,
- **Garantido (CRTR)**, colaboradores que tendem a ficar na empresa se forem tratados ou não (WIJAYA et al., 2021).

Figura 3 – Classes-alvo e classes de aprimoramento para problemas de rotatividade de funcionários



Fonte: Adaptado de Wijaya et al. (2021, p.55)

Para exemplificar o uso dessa abordagem basta criar um cenário hipotético onde uma companhia possui 100 colaboradores. Temos quatro grupos de vinte cinco colaboradores cada um deles classificado de acordo com uma classe de elevação, isto é, classificados como garantido, não perturbe, persuasíveis e causa perdida.

Se não aplicado nenhum tratamento de retenção de funcionários nestes 100 colaboradores, tende aos grupos de causa perdida e persuasíveis abandonarem a empresa. Contudo, os persuasíveis podem deixar a empresa por não receberem ações de retenção. Entretanto, mesmo se aplicado um tratamento de retenção em todos os 100 colaboradores, o grupo de causa perdida abandonará a empresa, porém, os persuasíveis podem ser estimulados a permanecer, pois, receberam um tratamento. Por outro lado, o grupo não perturbe tende a abandonar o emprego, resultando assim no mesmo número de colaboradores retidos quando não aplicado nenhum tratamento. Entretanto nesta situação há despesas no investimento da empresa com o tratamento / ação aplicado em todos os colaboradores.

Para otimizar os resultados de retenção essa modelagem, a *Uplift* é aplicada para com menor custo possível alcançar o maior resultado, isto é, abordando apenas os 25 colaboradores que são persuasíveis, sem assim, causar o abandono por parte dos não perturbe, alcançando um número de retenção de 75 funcionários, como pode

ser visto no Quadro 4 onde o custo é representado por um valor unitário, visto que esse cenário é apenas com intuito de exemplificar a importância dessa abordagem.

Quadro 4 – Cenário hipotético de resultado de abordagem de retenção de colaboradores

Cenário	Custa	Retem
Não aplicar nenhum tratamento		50
Aplicar tratamento a todos	100	50
Aplicar tratamento apenas aos persuasíveis	25	75

Fonte: Elaborado pelo autor

5 PROPOSTA DE APLICAÇÃO DE IA NO APOIO A GERAÇÃO DO *SHORTLIST* A PARTIR DAS CARACTERÍSTICAS DE PERSONALIDADE

Assim como já mencionado na Seção 4.8, as análises preditiva e prescritiva podem ser utilizadas para aplicar abordagens de Aprendizado de Máquina para prever e resolver muitos tipos de problemas que podem acontecer no futuro. Por esta razão constantemente surgem novos estudos sobre modelos preditivos focados na retenção de colaboradores, e técnicas para melhorar a base de dados utilizada nos treinamentos destes modelos, a fim de conseguir alcançar melhores resultados nas predições.

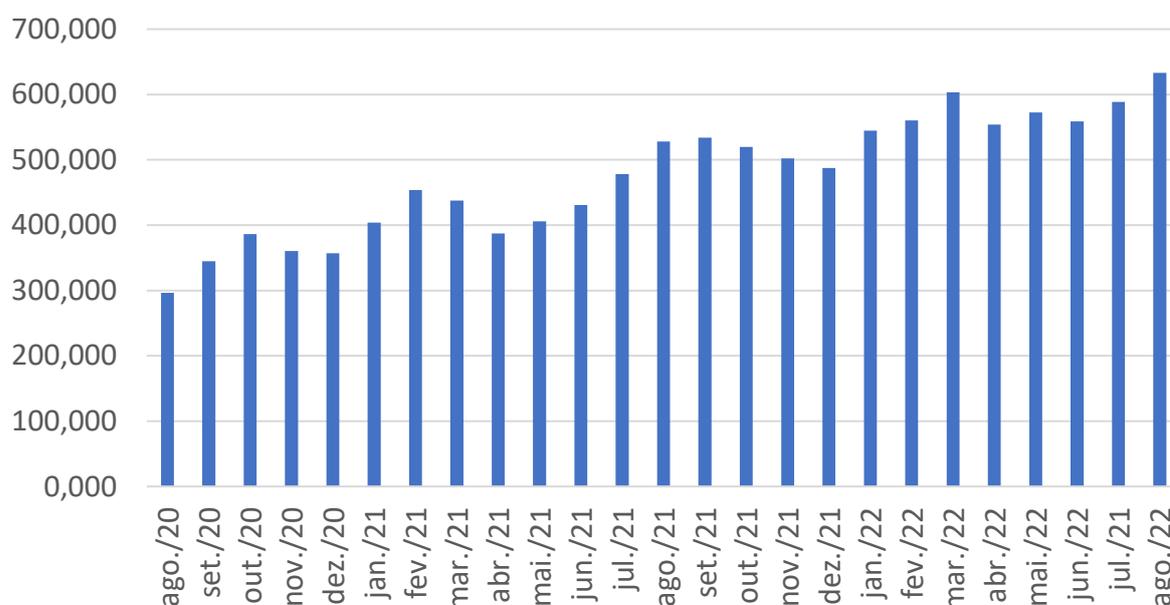
Como apresentado por Wijaya et al. (2021) em sua pesquisa, modelos de elevação apresentam melhores resultados na retenção de colaboradores, visto que, este modelo foca em identificar candidatos que tendem a ter uma reação positivo quando direcionados a um tratamento. Desta forma este trabalho propõe o uso da Modelagem Uplift, como um auxílio na geração do *shortlist* a partir da análise de personalidades de candidatos, utilizando para isso umas das possíveis abordagens que se aplica quando o foco é retenção de funcionários, neste caso a comumente denominada em inglês de *Employee Turnover Uplift* (ETU). Entretanto, diferente da abordagem comum, o objetivo desta proposta é desenvolver experimentos com aprendizado de máquina para geração de *shortlists* que identifiquem candidatos com propensão a permanecer no emprego, recebendo ou não qualquer tipo de tratamento.

Uma análise desenvolvida pela LCA Consultores e apresentada por Marta Cavallini (2022) no site de notícias G1, demonstra o aumento de pedidos de demissão espontânea por parte dos funcionários (Figura 4). O artigo apresenta como uma das principais razões a busca por melhora na qualidade de vida, cargos mais adequados à suas qualificações e maior alinhamento da empresa com suas expectativas pessoais, como por exemplo ascensão na carreira. Evidenciando assim a importância por buscas de novos métodos para predizer candidatos que possuem maior aderência a vagas ofertadas pelas empresas.

Desta forma o *dataset* utilizado no treinamento e teste do modelo é apresentado por Baduskin (2017). A escolha desta fonte se dá pelo fato de também conter os principais atributos com traços de personalidade de candidatos, assim como dados adquiridos antes de uma contratação, pois, como apresentado por Jayaratne e

Jayatilleke (2020), psicólogos organizacionais há muito tempo formulam a hipótese de que a personalidade de uma pessoa está intimamente relacionada a seus desempenhos no trabalho, satisfação e planejamento de carreira.

Figura 4 – Aumento de pedido de demissão voluntária



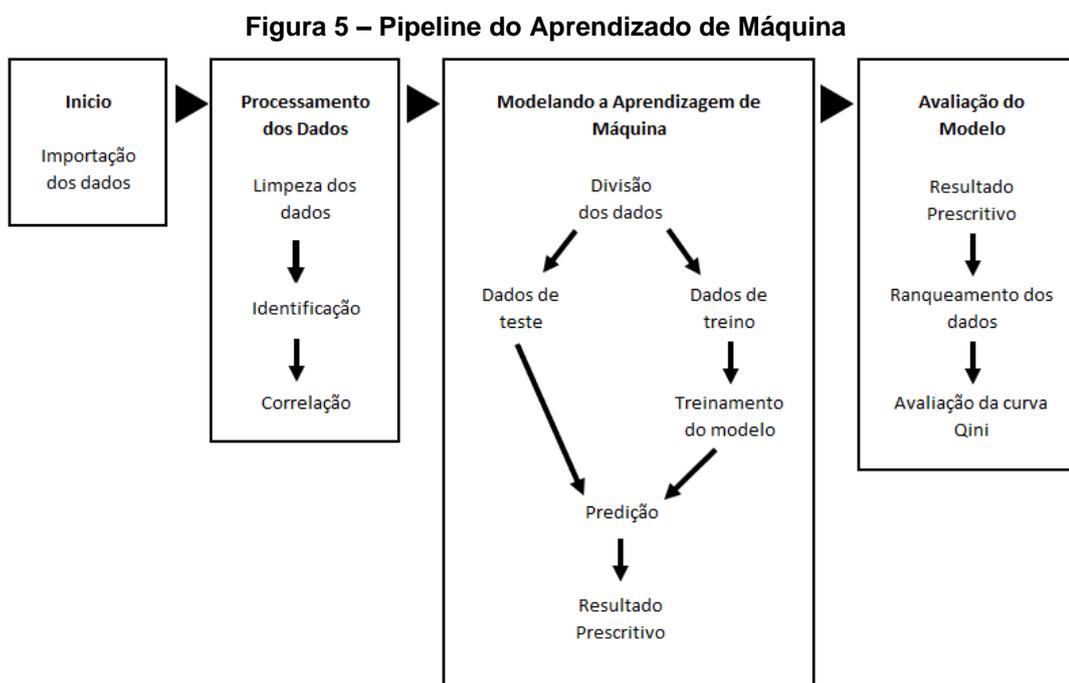
Fonte: Adaptado de Cavallini (2022)

5.1 METODOLOGIA

A metodologia proposta por Wijaya et al. (2021) é a mesma aplicada no desenvolvimento desta modelagem, que consiste em quatro etapas: a **importação dos dados**, o **pré-processamento** de dados, a **modelagem** do aprendizado de máquina e **avaliação**, que são visualizadas na Figura 5 como a pipeline de aprendizado de máquina. A diferença entre esta proposta e a de Wijaya et al. (2021) é o momento que o modelo é utilizado e a origem dos atributos inseridos no dataset, isto é, este trabalho propõe utilizar a modelagem de elevação como ferramenta de apoio para a geração de *shortlist* de candidatos, por este motivo, essa abordagem deve ser feita como uma das etapas iniciais do processo seletivo, diferente da proposta de Wijaya et al. (2021) que visa utilizar esta modelagem como ferramenta para identificar funcionários que terão uma reação positiva quando direcionados a um tratamento de retenção de funcionários, sendo assim, sua proposta é aplicada após a

contratação dos funcionários utilizando dados históricos adquiridos durante o tempo de contratos dos colaboradores, diferente dos dados utilizados para a modelagem da proposta deste trabalho onde além dos traços de personalidades, são usados atributos adquiridos antes da contratação.

O *dataset* utilizado é composto por dados reais compartilhado por Baduskin (2017) e que também foi utilizado por Wijaya et al. (2021) em seu estudo, assim como fornecido no site Kaggle como *dataset* de estudo para predição de rotatividade de funcionários. Os dados fornecidos consistem em 16 características por registro, entre as quais estão os cinco fatores que compõem o modelo Big Five de personalidade e uma quantidade de 1131 registros de empregados.



Fonte: Elaborado pelo autor

Diferente de todos os trabalhos desenvolvidos que foram identificados utilizando esta mesma base de dados, o corrente trabalho utilizou apenas as informações de personalidade (Big Five), meio de locomoção, gênero, idade, se houve tratamento de retenção e se saiu ou se manteve no emprego. Porém como esse *dataset* possui mais de uma área de atuação, foi necessário também utilizar os campos de indústria e profissão para auxiliar na modelagem. Removendo então os

atributos de tempo de experiencia, como o colaborador encontrou o emprego, sexo do supervisor e a forma que é pago seu salário.

No Quadro 5 é apresentado como as informações são oferecidas no *dataset* antes de qualquer tratamento, assim como, na última coluna é informado se o atributo é utilizado ou não no experimento proposto neste trabalho.

Quadro 5 – Estrutura do *dataset* utilizado no experimento.

Atributo	Nome em português	Tipo	Descrição	Utilizado no experimento
stag	Estágio	Decimal	Tempo de experiência, não informado se é referente à dias meses outro.	Não
event	Evento	Inteiro	Colaborador deixou do emprego ou não.	Sim
gender	Gênero	Caracter	Caracter que define se o sexo biológico é masculino ou feminino.	Sim
age	Idade	Inteiro	Idade do indivíduo	Sim
industry	Indústria	Texto	Nome do tipo de indústria, exemplo, "bank".	Sim
profession	Profissão	Texto	Nome da profissão, exemplo, "RH".	Sim
traffic	Trafego	Texto	Como o colaborador chegou à empresa, site, indicação, etc.	Não
coach	Treinamento	Texto	Definição se houve treinamento durante o período de estágio ou não.	Sim
head_gender	Gênero do supervisor	Caracter	Caracter que define se o sexo biológico do supervisor é masculino ou feminino.	Não
greywage	Salário cinza	Texto	Greywage na Rússia ou na Ucrânia significa que o empregador (empresa) paga apenas uma pequena quantia de salário acima do salário mínimo.	Não
way	Forma	Texto	Definição de como o colaborador vai ou ia ao trabalho.	Sim
extraversion	Extroversão	Decimal	Pontuação de 0 a 10 para definir o grau do traço de Extroversão (Big Five)	Sim
independ	Independente	Decimal	Pontuação de 0 a 10 para definir o grau do traço de Amabilidade (Big Five)	Sim
selfcontrol	Auto-controle	Decimal	Pontuação de 0 a 10 para definir o grau do traço de Conscienciosidade (Big Five)	Sim
anxiety	Ansiedade	Decimal	Pontuação de 0 a 10 para definir o grau do traço de Neuroticismo (Big Five)	Sim
novator	Inovador	Decimal	Pontuação de 0 a 10 para definir o grau do traço de Abertura (Big Five)	Sim

Fonte: Elaborado pelo autor

5.1.1 Pré-processamento

O pré-processamento consiste na transformação dos dados antes de inseri-los no algoritmo, como demonstrado na Figura 5, coluna Processamento de dados, essa etapa possui três partes. **Limpeza de dados**, onde são removidas informações desnecessárias para a análise, assim como, é feita a conversão de dados do tipo texto para numéricos. **Identificação**, que visa desbloquear a capacidade prescritiva de um conjunto de dados com um tratamento não identificado, isto é, identificar informações que demonstrem que houve tratamentos aplicados aos funcionários e se estes se mantiveram na empresa, e **correlação**, que objetiva analisar se o tratamento tem correlação significativa com a rotatividade dos colaboradores.

Para a conversão dos dados foram utilizados One-hot Encoder e Label Encoder, dos pacotes Scikit-learn e Pandas, respectivamente. A Label Encoder é utilizada para codificar dados de texto com hierarquia para inteiros, por exemplo se o colaborador teve ou não um tratamento de retenção, convertendo de sim e não para 1 e 0. Já o One-hot Encoder é utilizado para codificar dados categóricos, como por exemplo, o tipo de indústria, o sexo do colaborador, a forma que o colaborador vai ao trabalho, entre outros.

Observa-se que ao inverter o parâmetro de tratamento na base de dados (de 0 para 1 e vice-versa), também inverterá o valor e correlação do tratamento como apresentado no quadro 6 e fornecerá um cenário prescrito diferente. Portanto duplicar o conjunto de dados e inverter o parâmetro de tratamento resultará em um novo experimento. A função de correlação de Pearson do pacote Pandas é usada para calcular a correlação de tratamento antes de construir o modelo.

Quadro 6 – Correlação de tratamento e abandono do emprego

Parâmetro de tratamento original			Parâmetro de tratamento invertido		
	Tratamento	Abandono		Tratamento	Abandono
Tratamento	1	0,04	Tratamento	1	-0,04
Abandono	0,04	1	Abandono	-0,04	1

Fonte: Elaborado pelo autor

5.1.2 Modelagem do aprendizado de máquina

Para o desenvolvimento do modelo de Aprendizado de Máquina proposto foi desenvolvido com as seguintes etapas:

- **Divisão de dados**, etapa ao qual o conjunto de dados é dividido em duas partes, dados de treinamento e dados de teste, com a proporção de 70% e 30%, respectivamente, além de, aplicar uma amostragem estratificada aleatória com variável de tratamento para evitar o desequilíbrio de dados (DEVRIENDT; BERREVOETS; VERBEKE, 2019).
- **Treinamento do modelo**, onde o algoritmo XGB é usado para treinar o modelo com os dados de treinamento, pois, como já citado no corrente trabalho, este é o algoritmo que apresenta melhor resultado ao combinar com LGWUM, ressaltando que na comparação feita por Zhoa (2018) foram utilizadas as configurações padrão fornecido pelo pacote XGB. E por último a **predição**, ao qual os dados de testes são usados para prever o modelo que foi treinado com o algoritmo XGB, resultando em dados de predição e probabilidade.

5.1.3 Avaliação

Para avaliar o modelo treinado pode ser aplicada uma variedade de métodos, e todos apresentam o desafio de como avaliar o resultado, pois os modelos de elevação sofrem do problema fundamental da inferência causal. Existem três métodos diferentes para avaliar modelos de elevação na literatura, caixas de elevação ou em inglês *bins of uplift*, curva de elevação ou *uplift curve* e por último a medida de Qini, ou *Qini measures*.

As caixas de elevação limitam-se a avaliar a elevação de um único modelo e não pode ser usado para aplicar comparação entre modelos, a curva de elevação permite visualizar o ganho cumulativo do modelo e pode ser usado como uma ajuda para decidir a proporção do grupo de tratamento que deve receber o tratamento, a partir da curva de elevação, pode-se calcular o coeficiente de Gini, que é usado como medida para comparar diferentes modelo de elevação. A curva de Qini é um

desenvolvimento adicional da curva de elevação, que consegue capturar um efeito potencialmente negativo dos indivíduos da amostra, o que fornece uma visão melhor do desempenho do modelo. O coeficiente de Qini é semelhante ao coeficiente de Gini, o que permite a comparação do modelo (KARLSSON, 2019).

Desta forma são utilizados dois métodos para a validação do modelo treinado, a **precisão** e a **curva de Qini**. A precisão é a medida utilizada para medir o desempenho preditivo, isto é, se o resultado binário acertou ou não a previsão feita. Trazendo para o contexto do trabalho, a precisão é a medida utilizada para medir se o modelo consegue prever se o colaborador tende a sair da empresa, para isso, foi utilizado o pacote Scikit-learn para o cálculo de precisão. Por outro lado, a curva de Qini, como já mencionado, é uma versão adaptada do coeficiente de Gini. Além disso, os gráficos são frequentemente usados para a avaliação visual, e para o desenvolvimento do trabalho corrente foi utilizado o pacote Seaborn na criação dos gráficos de curva Qini (DEVRIENDT; BERREVOETS; VERBEKE, 2019).

Radcliffe (2007) cita que inúmeras medidas de desempenho para modelos tradicionais dependem fundamentalmente de uma comparação de resultados reais e previstos. Desta forma, após aplicado a previsão e aguardado um período suficiente para alguma ação ser tomada, é possível identificar se a previsão estava correta ou não. Porém essas medidas são inadequadas para casos de elevação, porque nunca é possível ter uma medida definida para um indivíduo, pois o mesmo nunca será simultaneamente tratado e não tratado para que se possa comparar os resultados. Desta forma, apenas pode ser estimada por segmento, por esta razão o coeficiente de Qini foi utilizada na proposta apresentada.

Quando iniciado o gráfico com a curva de Qini, pode-se perceber que é o mesmo que um gráfico de ganho da curva de Gini, exceto pelo eixo vertical, que agora mostra o aumento alcançado onde antes mostrava o número de respostas obtidas. Isso é estimado por segmento comparando a taxa de sucesso (o não abandono da empresa) no grupo tratado e o grupo de controle correspondente. O número estimado de sucessos incrementais em um segmento é dado por $QINI = TR - [(CR * T)/C]$ e pode ser normalizado em percentual da seguinte forma $QINI = (TR/T) - (CR/C)$.

5.3 RESULTADOS OBTIDOS

Após explorar e limpar o conjunto de dados foi identificado com sucesso uma variável representando um tratamento aplicado aos colaboradores afim de evitar a saída destes, assim como, a variável referente ao abandono da organização. Então foi dividido o conjunto de dados em dados de treinamento e dados de teste na proporção de 70% e 30% respectivamente, como pode ser confirmado no Quadro 7, e por fim, para treinar do modelo foi aplicado o algoritmo XGB.

Quadro 7 – Divisão dos dados e correlação entre tratamento e variável

alvo	
Dados de treinamento	570 registros
Dados de teste	245 registros
Correlação de tratamento com variável alvo (ou seja, rotatividade de funcionários)	4%

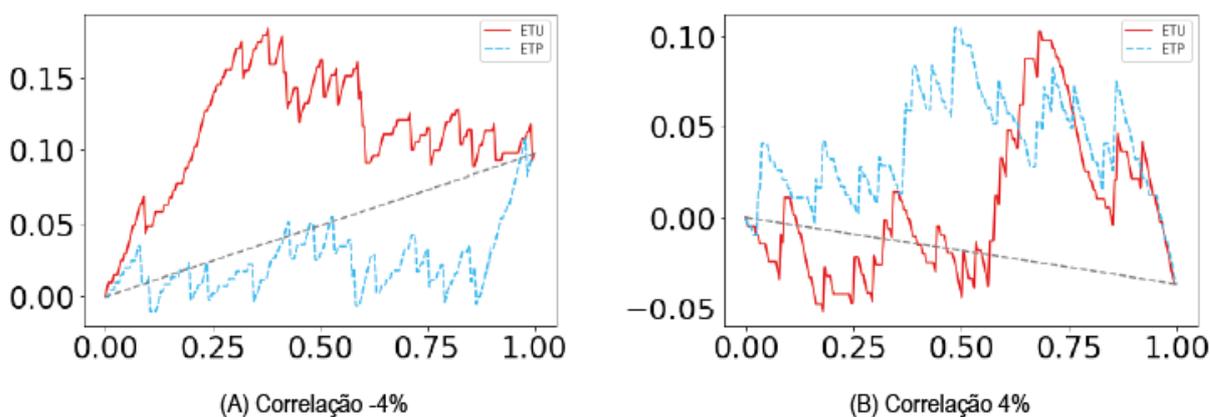
Fonte: Elaborado pelo autor

O Quadro 8 apresenta os resultados da previsão (ou seja, a previsão dos dados de teste com o modelo treinado) de um modelo tradicional, ETP, e do modelo *Uplift*, ETU. Após classificar os indivíduos pelo resultado da prescrição, a pontuação de elevação capturada pelos modelos ETP e ETU em cada segmentação é calculado com LGWUM, conforme a Figura 6, onde estão relacionados dois experimentos, um utilizando correlação negativa (experimento A) e o outro onde foram invertidos os parâmetros de tratamento da base de dados para capturar correlação positiva (experimento B). As curvas de Qini demonstram a proporção ideal de colaboradores que seriam tratados com algum programa de retenção. Também deve-se atentar-se às curvas positivas (apontando para cima), que indicam uma tendência do tratamento com correlação negativa, em reduzir a rotatividade de funcionários como demonstrando no experimento da A, ao contrário, o experimento B que apresenta curvas negativas devida à tendência de o tratamento com correlação positiva aumentar a rotatividade de funcionários.

Quadro 8 – Matriz de confusão resultado de precisão

		Positivo	Negativo	
Modelo ETP	Positivo	74	50	
	Negativo	43	78	
	Precisão Média	62,84%		
Modelo ETU	CN	Positivo	221	1
		Negativo	16	7
	CR	Positivo	226	2
		Negativo	16	1
	TN	Positivo	85	62
		Negativo	35	63
	TR	Positivo	90	48
		Negativo	46	61
	Precisão Média		53,48%	

Fonte: Elaborado pelo autor

Figura 6 – Curva de Qini

Fonte: Elaborado pelo autor

5.4 ANÁLISE DOS RESULTADOS

Os resultados da avaliação preditiva mostram que o modelo ETP produz 62,84% de precisão, enquanto o modelo ETU produz 53,48% de precisão. Os modelos ETP são treinados com o objetivo de prever a rotatividade de funcionário, enquanto os modelos ETU são treinados com objetivo de prescrever se o funcionário deve ser

alvo de um programa de retenção (WIJAYA et al., 2021). Portanto, é compreensível que modelos de predição superem o desempenho preditivo dos modelos de elevação. Contudo, quando analisadas, na Figura 5, as curvas de Qini, pode se observar como os modelos prescrevem os funcionários em cada segmentação, e fica visível que o modelo ETU tem melhor desempenho no experimento onde buscamos separar os funcionários persuadíveis dos não perturbe, e corroborando com isso, em ambos os testes o modelo ETU obteve coeficiente de Qini maior que 5%, que de acordo com Wijaya et al., (2021) isso significa que o modelo pode ser considerado de sucesso.

Portanto, como fica claro na Quadro 9 o modelo ETP atinge com sucesso apenas os colaboradores corretos em um experimento dos dois executados (ou seja, 50% de taxa de sucesso), de acordo com Devriendt, Berrevoets, Verbeke (2019) e Wijaya et al. (2021) intuitivamente usar o modelo ETP como análise prescritiva visando colaboradores com alto risco de rotatividade é uma abordagem sensata, entretanto, eles evidenciam e no corrente trabalho fortalecemos que, não é confiável para direcionar os funcionários a um tratamento. Por outro lado, em vez de assumir que os colaboradores com alto risco de rotatividade serão retidos se forem alvo de algum programa de retenção, o modelo ETU tem como alvo os funcionários certos em ambos os experimentos, ou seja 100% de taxa de sucesso.

Quadro 9 – Coeficiente de Qini

Correlação de tratamento -4%	Modelo ETP	-12,92%
	Modelo ETU	20,66%
Correlação de tratamento 4%	Modelo ETP	13,00%
	Modelo ETU	14,17%

Fonte: Elaborado pelo autor

O objetivo desta aplicação é auxiliar na geração de um *shortlist*, logo o foco é encontrar candidatos que não irão gerar custos adicionais com recontração, por esse motivo tem como alvo candidatos que tendem a não saírem da empresa, mesmo, quando não receberem nenhum tipo de tratamento. Porém, como foi visto um modelo tradicional teve apenas 62,84% de precisão, diferente de um modelo de elevação que podemos mirar nas classes de elevação CR ou TR, e evitando funcionários CN e TN.

Desta forma o modelo de elevação se mostra mais confiável como uma ferramenta de auxílio no ranqueamento de candidatos a fim gerar um *shortlist*, utilizando suas características de personalidade e dados que já se pode ter antes de uma efetiva contratação. Contudo, vale ressaltar, que evidências empíricas de modelo de elevação superando modelos preditivos convencionais estão crescendo constantemente na literatura. Portanto, estudos comparativos entre várias estratégias de modelagem *Uplift* ainda precisam ser explorados para descobrir estratégias mais confiáveis, assim como, técnicas para melhorar o desempenho também precisam ser exploradas, por exemplo, algoritmos de aprendizado de máquina, engenharia de recursos etc.

6 CONCLUSÃO

A área da Inteligência Artificial está crescendo rapidamente e assumindo lugares que antes não imaginávamos sendo operado por computadores, antes apenas visto em filmes, hoje já é realidade vemos veículos autônomos, nos dispositivos de smart-home respondendo a comandos de voz, em sites de interação social filtrando postagens de acordo com a relevância para os usuários e em inúmeras operações organizacionais, como por exemplo no setor que RH.

Conforme apresentado neste trabalho e citado por Lopes (2021), existem evidências de uma melhora na qualidade de contratação, apoiados numa tomada de decisão mais precisa e inteligente, visto que a IA é capaz de analisar mais dados de cada candidato, isto é, competências, experiências, características da personalidade e identificação de padrões imperceptíveis que escapam ao ser humano, e com isso, é esperado que todo o processo, até a efetiva seleção do candidato, seja feito com justiça e imparcialidade.

Também é importante salientar o benefício associado a experiência dos candidatos no processo seletivo, visto que com o auxílio de assistentes virtuais, como *chatbots*, os candidatos poderão ter uma melhor interação, e flexibilidade no processo, assim como respostas mais rápidas e claras. Como já citado, uma grande e importante contribuição da IA, é a redução de potenciais viesamentos humanos, pois, a IA se concentrará em analisar dados que de fato agreguem valor à empresa, como competências, experiências, qualificações e não sexo, idade, aparência etc., desta forma diminuindo a possibilidade de discriminação e aumentando a diversidade e inclusão dentro da organização (LOPES, 2021).

Este trabalho teve início com o objetivo de investigar os meios com que o setor de Recursos Humanos emprega Inteligência Artificial no processo de recrutamento e seleção, assim como os riscos e desafios no emprego de IA enquanto ferramenta primal para o processo. No entanto, conforme identificado durante os estudos para fundamentação teórica e trabalhos relacionados, falhas no processo de recrutamento resultam no aumento das taxas de rotatividade de colaboradores. Com base nesta constatação, este trabalho estabeleceu ofoco em apresentar um experimento de Aprendizado de Máquina aplicado ao processo de recrutamento e seleção, com o objetivo de auxiliar e tornar o processo mais rápido, preciso e inteligente. Além disso,

também se tornar uma ferramenta para auxiliar na redução de taxas de rotatividade de funcionários, assim como reduzir custo de processo de retenção de colaboradores com foco em candidatos que tendem a se manter na empresa mesmo sem receberem nenhum tipo de tratamento, ou seja, processo de retenção de funcionários. Desta forma o uso da IA se mostra não apenas como uma ferramenta para auxiliar o setor de RH no processo de recrutamento, mas também, como já citado no início deste trabalho, uma vantagem competitiva para a organização.

Vale destacar que processos apoiados pelo uso da IA, somente terão resultados satisfatórios, se os dados utilizados forem de boa qualidade, isso é, dados atualizados e mais precisos possíveis. Analisando o experimento apresentado no trabalho, é aceitável considerar que uma parte do resultado obtido é por mérito da base de dados utilizada neste. Desta forma, obter estas informações dos candidatos pode ser um dos principais impeditivos para o uso desta abordagem em ambiente real atualmente, visto que, como apresentado no trabalho, na sua grande maioria os procedimentos que visam identificar características de personalidades do indivíduo são longos e cansativos, desta forma, a inserção de um requisito deste no processo de recrutamento pode se tornar um desmotivador para os candidatos.

Entretanto fora dos dados existem outros desafios que a IA vai enfrentar pela frente, um deles que por vezes pode ser um impeditivo de maior aceitação da sociedade no uso da IA, está relacionado com a privacidade, segurança e principalmente com a ética, e conforme destacados em vários trabalhos literários cada vez vem ganhando mais relevância. Como a IA está sendo cada vez mais usadas em tarefas cognitivas antes realizadas por humanos, surge a reflexão ética de como o meio empresarial vai fazer para garantir a integridade, legitimidade e a justiça às decisões tomadas apoiadas pela IA.

REFERÊNCIAS BIBLIOGRÁFICAS

ATANAZIO, A. et al. A Inteligência Artificial transformando o RH do futuro: um estudo de caso sobre a tecnologia e a diversidade no mercado de trabalho. **Refas - Revista Fatec Zona Sul**, v. 7, n. 4, p. 1–16, 30 abr. 2021.

BALAJI, M.; KUMAR, A. A.; MATHIMARAN, K. B. Employee Retention Strategies -An Empirical Research Employee Retention Strategies -An Empirical Research. **Global Journal of Management and Business Research: E Marketing**, v. 17, n. 1, 2017.

BABUSHKIN, Edward. Employee Turnover Dataset. 2017. Disponível em: <https://edwvb.blogspot.com/2017/10/employee-turnover-how-to-predict-individual-risks-of-quitting.html>. Acesso em: 16 novembro 2022.

CHEN, T.; GUESTRIN, C. XGBoost: A Scalable Tree Boosting System. **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16**, 2016.

CHIAVENATO, I. **Gestão de Pessoas: o novo papel dos recursos humanos nas organizações**. 3. ed. Rio de Janeiro: Elsevier, 2010.

DE LIMA, A. S. H.; RABELO, A. A. A IMPORTÂNCIA DO E-RECRUTAMENTO E SELEÇÃO ONLINE NO PROCESSO ORGANIZACIONAL. **Revista Psicologia, Diversidade e Saúde**, v. 7, n. 1, p. 147, 21 fev. 2018.

DEVRIENDT, F.; MOLDOVAN, D.; VERBEKE, W. A Literature Survey and Experimental Evaluation of the State-of-the-Art in Uplift Modeling: A Stepping Stone Toward the Development of Prescriptive Analytics. **Big Data**, v. 6, n. 1, p. 13–41, mar. 2018.

FERREIRA, B. DA P. **Inteligência artificial no recrutamento e seleção: amiga ou inimiga?: percepções e atitudes de profissionais de recrutamento e seleção portugueses**. dez. 2020

FRIEDMAN, J. H. **Greedy Function Approximation: A Gradient Boosting Machine**. fev. 1999.

GUBELA, R. et al. Conversion Uplift in E-Commerce: A Systematic Benchmark of Modeling Strategies. **International Journal of Information Technology & Decision Making**, v. 18, n. 03, p. 747–791, maio 2019.

JARRAHI, M. H. Artificial Intelligence and the Future of Work: Human-AI Symbiosis in Organizational Decision Making. **ResearchGate**, v. 61, n. 4, p. 577–586, jul. 2018.

JAYARATNE, M.; JAYATILLEKE, B. Predicting Personality Using Answers to Open-Ended Interview Questions. **IEEE Access**, v. 8, n. 2020, p. 115345–115355, 2020.

KANE, K.; LO, V. S. Y.; ZHENG, J. Mining for the truly responsive customers and

prospects using true-lift modeling: Comparison of new and existing methods. **Journal of Marketing Analytics**, v. 2, n. 4, p. 218–238, dez. 2014.

KARLSSON, H. **Uplift Modeling: Identifying Optimal Treatment Group Allocation and Whom to Contact to Maximize Return on Investment**. 2019. Dissertação (Mestrado em Estatística e Machine Learning) - Departamento de Ciência da Computação e da Informação Universidade de Linköping. Disponível em: <https://www.semanticscholar.org/paper/Uplift-Modeling-%3A-Identifying-Optimal-Treatment-and-Karlsson/7be1a37e2a0224259745e7e1217e02e2c2323cda>. Acesso em: 16 ago 2022

LOPES, J. R. G. M. **A inteligência artificial no processo de recrutamento e seleção: perspectivas dos gestores de recursos humanos sobre riscos e desafios**. 2021. 48 f. Dissertação (Mestrado Bolonha em Ciências Empresariais) - Instituto Superior de Economia e Gestão, Lisboa, 2021. Disponível em: <http://hdl.handle.net/10400.5/22751>. Acesso em: 16 ago 2022

MACCALI, N. et al. AS PRÁTICAS DE RECURSOS HUMANOS PARA A GESTÃO DA DIVERSIDADE: A INCLUSÃO DE DEFICIENTES INTELECTUAIS EM UMA FEDERAÇÃO PÚBLICA DO BRASIL. RAM. **Revista de Administração Mackenzie**, v. 16, n. 2, p. 157–187, abr. 2015.

RADCLIFFE, N. Using control groups to target on predicted lift: Building and assessing uplift model. **Direct Marketing Analytics Journal**, v. 1, n. 2007, p. 14–21, 2007.

SIMBECK, K. HR analytics and ethics. **IBM Journal of Research and Development**, v. 63, n. 4/5, p. 9:1–9:12, 1 jul. 2019.

SOUSA, D. I. P. **A importância do papel das novas tecnologias e da inteligência artificial nos processos de recrutamento e seleção**. 2021. 59 f. Dissertação (Mestrado em Gestão) - Universidade de Aveiro, Aveiro, 2021. Disponível em: <http://hdl.handle.net/10773/33036>. Acesso em: 29 maio 2022

SWARTZ, T. H. et al. The Science and Value of Diversity: Closing the Gaps in Our Understanding of Inclusion and Diversity. **The Journal of Infectious Diseases**, v. 220, n. Supplement_2, p. S33–S41, 19 ago. 2019.

TADESSE, M. M. et al. Personality Predictions Based on User Behavior on the Facebook Social Media Platform. **IEEE Access**, v. 6, n. 2018, p. 61959–61969, 2018.

TOLEDO, F. DE. **O que são os recursos humanos**. Editora Brasiliense, 2003.

USSELMANN, H.; AHMAD, R.; SIEMON, D. **A Personality Mining System for German Twitter Posts With Global Vectors Word Embedding**. v. 9p. 165576–165610

WANG, P. et al. Classification of Proactive Personality: Text Mining Based on Weibo Text and Short-Answer Questions Text. **IEEE Access**, v. 8, n. 2020, p. 97370–

97382, 2020.

WIJAYA, D. et al. Uplift modeling VS conventional predictive model: A reliable machine learning model to solve employee turnover. **International Journal of Artificial Intelligence Research**, v. 5, n. 1, 8 jan. 2021.

ZHAO, Y. et al. Employee Turnover Prediction with Machine Learning: A Reliable Approach. **Advances in Intelligent Systems and Computing**, n. 2018, p. 737–758, 8 nov. 2018. Disponível em: https://link.springer.com/chapter/10.1007/978-3-030-01057-7_56. Acesso em: 5 ago. 2022

ZHAO, Y.; FANG, X.; SIMCHI-LEVI, D. Uplift Modeling with Multiple Treatments and General Response Types. **Proceedings of the 2017 SIAM International Conference on Data Mining**, n. 2017 p. 588–596, 9 jun. 2017. Disponível em: <https://doi.org/10.1137/1.9781611974973.66>. Acesso em: 3 ago. 2022