INTERPRETABILIDADE E ÉTICA: PRIVACIDADE, TRANSPARÊNCIA E RESPONSABILIZAÇÃO EM MODELOS PREDITIVOS DE QUALIDADE DE VIDA NO TRABALHO

INTERPRETABILITY AND ETHICS: PRIVACY, TRANSPARENCY AND ACCOUNTABILITY IN PREDICTIVE MODELS OF QUALITY OF WORK LIFE

KAROLINE FARIA DE MIRANDA
UNIVERSIDADE FEDERAL DO PARANÁ - UFPR

MARCELO MAIA
CENTRO UNIVERSITÁRIO UNISENAI

Comunicação:
O XIV SINGEP foi realizado em conjunto com a 14th Conferência Internacional do CIK (CYRUS Institute of Knowledge) e com a SPARK (Society for Promoting Academic Research and Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

INTERPRETABILIDADE E ÉTICA: PRIVACIDADE, TRANSPARÊNCIA E RESPONSABILIZAÇÃO EM MODELOS PREDITIVOS DE QUALIDADE DE VIDA NO TRABALHO

Objetivo do estudo
Analisar os princípios de ética de dados que incidem sobre cada etapa de um pipeline preditivo de Qualidade de Vida no Trabalho e defender que a interpretabilidade do modelo é uma exigência ética, não apenas um recurso técnico.

Relevância/originalidade
A literatura já mapeia os riscos éticos do people analytics, mas raramente os liga às escolhas metodológicas concretas de um modelo preditivo de QVT sob a LGPD. O ensaio ocupa essa lacuna.

Metodologia/abordagem
Ensaio teórico-analítico com percurso argumentativo dedutivo: parte de princípios consolidados na literatura de ética de dados e da LGPD, decompõe o pipeline em seis etapas do ciclo de vida dos dados e cruza princípios e etapas.

Principais resultados
Uma matriz que associa, a cada etapa, o risco ético predominante e sua mitigação. Os riscos mais graves concentram-se nas extremidades, coleta e uso, onde as decisões são humanas e institucionais, não algorítmicas.

Contribuições teóricas/metodológicas
Propõe a interpretabilidade como categoria ética autônoma, não subsumida à transparência, situando o argumento de Rudin no contexto da LGPD e da subordinação própria do trabalho. Os coeficientes Beta padronizados tornam-se instrumento de prestação de contas.

Contribuições sociais/para a gestão
Oferece a gestores um instrumento prático para desenhar iniciativas de bem-estar sem transformá-las em vigilância: base legal adequada, uso agregado e formativo dos resultados, supervisão humana e limites que protegem quem respondeu.

Palavras-chave: Ética de dados, Qualidade de Vida no Trabalho, Modelo preditivo, LGPD

INTERPRETABILITY AND ETHICS: PRIVACY, TRANSPARENCY AND ACCOUNTABILITY IN PREDICTIVE MODELS OF QUALITY OF WORK LIFE

Study purpose
To analyse the data ethics principles that bear on each stage of a predictive pipeline for Quality of Work Life, and to argue that model interpretability is an ethical requirement rather than merely a technical resource.

Relevance / originality
The literature already maps the ethical risks of people analytics, but it rarely connects them to the concrete methodological choices of a QWL predictive model under Brazilian data protection law. This essay addresses that gap.

Methodology / approach
A theoretical-analytical essay following a deductive argumentative path: it starts from principles consolidated in the data ethics literature and in the LGPD, breaks the pipeline into six stages of the data life cycle, and cross-references principles and stages.

Main results
A matrix linking each stage to its predominant ethical risk and corresponding mitigation. The most serious risks cluster at the ends of the pipeline, collection and use, where decisions are human and institutional rather than algorithmic.

Theoretical / methodological contributions
It proposes interpretability as an autonomous ethical category, not subsumed under transparency, situating Rudin's argument within the LGPD and the subordination inherent to employment. Standardised Beta coefficients thus become an instrument of accountability.

Social / management contributions
It offers managers a practical instrument for designing well-being initiatives without turning them into surveillance: an appropriate legal basis, aggregated and formative use of results, human oversight, and limits that protect those who responded.

Keywords: Data ethics, Quality of Work Life, Predictive model, Brazilian General Data Protection Law (LGPD)

INTERPRETABILIDADE E ÉTICA: PRIVACIDADE, TRANSPARÊNCIA E RESPONSABILIZAÇÃO EM MODELOS PREDITIVOS DE QUALIDADE DE VIDA NO TRABALHO

RESUMO

Este ensaio teórico-analítico discute as implicações éticas de se predizer a Qualidade de Vida no Trabalho (QVT) a partir de dados de trabalhadores. Por meio de percurso argumentativo de base dedutiva, o texto articula seis categorias éticas às etapas do ciclo de vida dos dados: cinco delas :privacidade, finalidade, transparência, responsabilização e equidade, convergentes na literatura de ética de dados, e uma sexta a interpretabilidade. proposta e defendida pelo próprio ensaio. Sua principal contribuição é o argumento de que a interpretabilidade do modelo, tornada possível por algoritmos lineares regularizados e pela leitura dos coeficientes Beta padronizados, é uma exigência ética, e não apenas uma qualidade técnica: é ela que torna auditável a produção das estimativas, concretiza os princípios de transparência e prestação de contas e operacionaliza, quando cabível, o direito de revisão de decisões automatizadas. Ao final, propõe-se uma matriz de riscos e mitigações pensada para o caso da QVT, acompanhada de uma leitura transversal de suas implicações para a governança do pipeline.

Palavras-chave: Ética de dados. Qualidade de Vida no Trabalho. Modelo preditivo. LGPD.

ABSTRACT

This theoretical-analytical essay discusses the ethical implications of predicting Quality of Work Life (QWL) using workers' data. Through a deductive argumentative approach, the study maps six ethical categories onto the stages of the data life cycle: five of them: privacy, purpose limitation, transparency, accountability, and fairness, convergent in the data ethics literature, and a sixth interpretability proposed and defended by the essay itself. Its main contribution is the argument that model interpretability, enabled by regularized linear algorithms and the interpretation of standardized beta coefficients, is an ethical requirement rather than merely a technical attribute. Interpretability makes the generation of predictions auditable, gives concrete expression to the principles of transparency and accountability, and operationalizes, where applicable, the right to review automated decisions. Finally, the study proposes a risk and mitigation matrix specifically designed for the context of Quality of Work Life, followed by a cross-cutting reading of its implications for pipeline governance.

Keywords: Data ethics. Quality of Work Life. Predictive model. Brazilian General Data Protection Law (LGPD).

1 INTRODUÇÃO

O people analytics é a aplicação de métodos analíticos a dados de trabalhadores para orientar a gestão (Tursunbayeva et al., 2018). Em uma sociedade na qual os dados pessoais se consolidaram como ativos econômicos e estratégicos (Garbaccio & Kischelewski, 2024), as organizações passaram a medir e a tentar prever também a Qualidade de Vida no Trabalho (QVT), construto que reúne a percepção dos trabalhadores sobre as condições e o sentido do que fazem no ambiente de trabalho (Walton, 1973; Limongi-França, 2004; Ferreira, 2012).

Utilizar da modelagem preditiva para a QVT a partir de dados de trabalhadores significa coletar, guardar e processar informações sobre pessoas que estão em relação de subordinação, para gerar estimativas capazes de orientar decisões que as afetam. É aí que surgem as questões colocadas pela ética de dados: privacidade, consentimento, finalidade, transparência, responsabilização. e que, se ignoradas, podem transformar uma iniciativa de bem-estar em

instrumento de vigilância ou de discriminação (Floridi & Taddeo, 2016; Mittelstadt et al., 2016; Gal et al., 2020).

Este artigo procura unir a discussão ética às escolhas metodológicas concretas de um pipeline de predição de QVT, sobretudo sob a Lei Geral de Proteção de Dados (LGPD). Toma-se como objeto de análise um pipeline de predição de QVT com modelos lineares regularizados, como as regressões Ridge (Hoerl & Kennard, 1970), LASSO (Tibshirani, 1996) e Elastic Net (Zou & Hastie, 2005). O objetivo é duplo: mapear os princípios de ética de dados que incidem sobre cada etapa desse pipeline e defender a tese de que a interpretabilidade do modelo é, antes de tudo, uma exigência ética, e não apenas um recurso técnico. Diferentemente de Rudin (2019), que formula esse argumento no plano geral dos domínios de alto risco, este ensaio o situa no contexto jurídico brasileiro da LGPD e na relação de subordinação própria do trabalho.

2 QUALIDADE DE VIDA NO TRABALHO E OS RISCOS ÉTICOS DO PEOPLE ANALYTICS

A QVT é um construto abrangente. Desde a formulação pioneira de Walton (1973), costuma abranger a justiça na remuneração, as condições de saúde e segurança, as oportunidades de usar e desenvolver capacidades, a integração social e o equilíbrio entre trabalho e vida. No Brasil, Limongi-França (2004) consolidou uma leitura biopsicossocial e organizacional, enquanto Ferreira (2012) deslocou o foco para o olhar dos próprios trabalhadores, entendendo a QVT a partir das representações que eles constroem sobre o próprio bem-estar.

Quando a QVT vira objeto de modelagem preditiva, o trabalhador é, em alguma medida, convertido em dado. A literatura crítica sobre people analytics mostra que esse processo não é neutro. Gal et al. (2020) descrevem um ciclo vicioso de opacidade algorítmica, dataficação e nudging que pode corroer a autonomia e o florescimento das pessoas. Tursunbayeva et al. (2021), em revisão sobre a ética do campo, apontam perigos recorrentes, como a vigilância excessiva, a assimetria de poder e a erosão da privacidade, alertando que o discurso da área tende a ser otimista e tecnocêntrico, minimizando esses riscos. É contra esse pano de fundo que se coloca a pergunta ética deste ensaio.

3 ÉTICA DE DADOS, VIÉS ALGORÍTMICO E A LGPD

A ética de dados se ocupa dos problemas morais ligados a dados, algoritmos e às práticas que os cercam (Floridi & Taddeo, 2016). Mittelstadt et al. (2016) organizam esse debate em torno de preocupações como a opacidade das evidências produzidas, a chance de resultados injustos, os efeitos sobre a autonomia das pessoas e a dificuldade de saber a quem responsabilizar quando algo dá errado. No plano das diretrizes, Jobin et al. (2019) mostram que documentos do mundo todo convergem para um núcleo comum: transparência, justiça, não maleficência, responsabilização e privacidade.

A questão da equidade merece atenção especial. Barocas e Selbst (2016) mostram que sistemas baseados em dados podem discriminar mesmo sem qualquer intenção, quando apenas reproduzem padrões enviesados já presentes nos dados. Mehrabi et al. (2021) organizam as diferentes fontes de viés e as noções de justiça em aprendizado de máquina. No caso da QVT, o risco é palpável: uma base pouco representativa pode gerar estimativas sistematicamente distorcidas e genéricas para certos grupos de trabalhadores.

A LGPD (Brasil, 2018) fixa princípios como finalidade, adequação, necessidade, transparência e prestação de contas (art. 6º); exige uma base legal para o tratamento e chama atenção para a fragilidade do consentimento em relações desiguais (arts. 7º e 8º); protege de forma reforçada os dados sensíveis, categoria que pode alcançar informações de saúde e bem-

estar (art. 11); e garante ao titular o direito de pedir a revisão de decisões tomadas unicamente por meios automatizados (art. 20).

Cabe, ainda, uma precisão sobre as bases legais da LGPD (Brasil, 2018). Embora o consentimento (art. 7º, I) seja a via mais lembrada, ele não é o único fundamento possível e, em relações marcadas por assimetria de poder, tampouco o mais adequado. Para a pesquisa acadêmica, a própria lei prevê a realização de estudos por órgão de pesquisa como base autônoma (art. 7º, IV, e art. 11, II, alínea "c"), hipótese em que o consentimento deixa de operar como fundamento jurídico do tratamento e permanece como salvaguarda ética, nos termos das Resoluções CNS nº 466/2012 e nº 510/2016, esta última específica para pesquisas em Ciências Humanas e Sociais, caso dos estudos de QVT baseados em instrumentos de percepção (Brasil, 2012, 2016). No ambiente corporativo, discute-se ademais o legítimo interesse (art. 7º, IX), condicionado a teste de balanceamento que demonstre a não prevalência de riscos aos direitos e liberdades fundamentais do titular. Desses referenciais, somados à lei, extraem-se as categorias que guiam a análise, detalhadas na seção seguinte.

4 PERCURSO METODOLÓGICO

O presente artigo configura-se como ensaio teórico-analítico (Meneghetti, 2011), conduzido por percurso argumentativo de base dedutiva: parte-se de princípios consolidados na literatura de ética de dados e no marco legal brasileiro para examinar, por dedução, suas implicações sobre um pipeline preditivo de QVT. Como ensaio, o texto não busca comprovação empírica nem pretende revisar exaustivamente a literatura; seu compromisso é com a originalidade da reflexão e o rigor da argumentação (Meneghetti, 2011). Nesse sentido, os referenciais mobilizados, as formulações seminais e revisões de ética de dados, de algoritmos e de people analytics discutidas nas seções 2 e 3 (Floridi & Taddeo, 2016; Mittelstadt et al., 2016; Barocas & Selbst, 2016; Jobin et al., 2019; Tursunbayeva et al., 2021), operam como fundamento teórico da argumentação, ao lado da LGPD (Brasil, 2018) como marco normativo, e não como corpus resultante de busca sistemática em bases de dados.

O percurso analítico teve três passos. Primeiro, definiram-se cinco categorias de análise a priori: privacidade, finalidade, transparência, responsabilização e equidade, extraídas desses referenciais e da lei por serem princípios que neles aparecem de forma convergente (Jobin et al., 2019). A sexta categoria, a interpretabilidade, não figura como princípio autônomo entre os convergentes mapeados por Jobin et al. (2019), nos quais noções de explicabilidade aparecem subsumidas à transparência; ela é proposta e defendida neste ensaio, a partir do argumento de Rudin (2019), como desdobramento ético necessário da predição de QVT em contexto de subordinação, constituindo parte de sua contribuição. Segundo, decompôs-se o pipeline de predição de QVT em seis etapas do ciclo de vida dos dados: coleta, armazenamento, pré-processamento, modelagem, interpretação e uso (Saltz & Shamshurin, 2016). Terceiro, cruzou-se cada categoria com cada etapa, identificando o risco ético predominante e a mitigação cabível, resultado consolidado na matriz da seção 7.

5 O PIPELINE DE PREDIÇÃO DE QVT À LUZ DO CICLO DE VIDA DOS DADOS

Na coleta, o problema começa pela assimetria de poder. O consentimento que a LGPD (Brasil, 2018) exige (art. 7º) tende a ser frágil quando quem pede é justamente quem decide sobre a permanência do trabalhador, de forma que a voluntariedade fica comprometida, razão pela qual a base legal de estudos por órgão de pesquisa, discutida na seção 3, é preferível no contexto acadêmico. Há ainda o risco de os dados reunidos para medir QVT acabarem sendo reaproveitados para avaliar desempenho ou justificar desligamentos, o que fere o princípio da finalidade (art. 6º, I). Como mitigação, recomendam-se um Termo de Consentimento Livre e Esclarecido elaborado em linguagem acessível, mantido como salvaguarda ética (Brasil, 2012,

2016), o compromisso estrito com a finalidade declarada, a coleta do mínimo de informações necessárias: privilegiando instrumentos validados com escores globais e evitando itens invasivos coletados isoladamente, e, quando possível, a mediação de um terceiro independente para reduzir constrangimentos decorrentes da relação entre pesquisador e empregador.

No armazenamento, os riscos são a reidentificação e o acesso indevido a dados que, por tratarem de bem-estar, podem ser sensíveis de acordo com o art. 11 da LGPD (Brasil, 2018); anonimização ou pseudonimização, controle de acesso e segurança da informação respondem a isso. No pré-processamento, escolhas aparentemente técnicas como excluir casos, imputar valores, padronizar, podem criar ou ampliar vieses (Barocas & Selbst, 2016; Mehrabi et al., 2021), o que pede documentação cuidadosa das decisões e verificação de representatividade da base.

Na modelagem, o risco central é a opacidade: um modelo cujo funcionamento não pode ser explicado transforma a estimativa em veredito incontestável (Mittelstadt et al., 2016; Rudin, 2019), agravado pela redução de um construto subjetivo a um escore. Na interpretação, os perigos são a atribuição causal indevida (Shmueli, 2010) e a instabilidade das leituras sob preditores correlacionados (Zou & Hastie, 2005). Essas duas etapas concentram a tese central deste ensaio, a de que a interpretabilidade é uma exigência ética, e não apenas um atributo técnico e, por isso, são aprofundadas na seção 6.

No uso, o perigo é que as estimativas embasem decisões que prejudiquem o trabalhador, razão para preferir um emprego agregado e formativo dos resultados, sob governança e supervisão humana, com divulgação restrita a recortes com número mínimo de respondentes, de modo a impedir a reidentificação de equipes pequenas, com revisão de decisões automatizadas, quando cabível, conforme o art. 20 da LGPD (Brasil, 2018).

6 INTERPRETABILIDADE COMO EXIGÊNCIA ÉTICA

A tese central deste ensaio é simples de enunciar: no caso da predição da QVT, a interpretabilidade não é só desejável, é uma exigência ética. O ponto de partida é reconhecer que decisões sobre o bem-estar de trabalhadores são decisões de alto risco. Elas acontecem em contexto de subordinação, tocam a saúde e a dignidade das pessoas e podem repercutir sobre o emprego; e, quase sempre, o trabalhador não tem como contestar uma estimativa que não entende. É esse tipo de situação que Rudin (2019) tem em mente ao defender, para domínios de alto risco, o uso de modelos que já sejam interpretáveis por construção, em vez de modelos opacos remendados com explicações posteriores.

Convém encarar a objeção mais comum: a de que existiria um trade-off inevitável entre acurácia e interpretabilidade e que, por isso, valeria a pena renunciar à clareza em nome do desempenho. Rudin (2019) argumenta que esse dilema costuma ser exagerado, sobretudo quando os dados são estruturados e tabulares, como escores de questionários, situação em que modelos interpretáveis alcançam desempenho parecido com o de modelos complexos.

Na prática, a utilização de modelos lineares regularizados, como Ridge, LASSO e Elastic Net, possibilita avaliar a contribuição relativa das variáveis preditoras por meio dos coeficientes Beta padronizados, favorecendo a interpretabilidade do modelo e a identificação dos preditores mais relevantes (Tibshirani, 1996; Zou & Hastie, 2005; James et al., 2021). Duas precisões técnicas, contudo, são necessárias para que essa promessa não seja superdimensionada. A primeira diz respeito à colinearidade: sob preditores correlacionados, como tendem a ser as dimensões de instrumentos multidimensionais de QVT, a regressão Ridge tende a repartir o encolhimento entre variáveis correlacionadas, enquanto o LASSO pode selecionar arbitrariamente uma dentre elas, o que fragiliza a estabilidade da leitura dos coeficientes (Zou & Hastie, 2005); por isso, recomenda-se preferir o Elastic Net nesse cenário (Zou & Hastie, 2005) e verificar a estabilidade dos coeficientes por reamostragem, como o

bootstrap (James et al., 2021). A segunda distingue os planos da explicação: os coeficientes oferecem interpretabilidade global do modelo, ao passo que a explicação de uma estimativa individual decorre da decomposição das contribuições de cada variável, o produto entre o valor observado e o respectivo coeficiente (Molnar, 2022).

Essa leitura direta dá corpo, em primeiro plano, aos princípios da transparência (art. 6º, VI) e da prestação de contas (art. 6º, X) da LGPD (Brasil, 2018). A rigor, o art. 20 alcança apenas decisões tomadas unicamente com base em tratamento automatizado, e o desenho aqui recomendado, com supervisão humana e uso formativo, situa-se fora dessa hipótese. A interpretabilidade permanece, contudo, como salvaguarda subsidiária: caso o uso derive para decisões automatizadas, é ela que operacionaliza o direito de revisão, permitindo demonstrar como determinada estimativa foi obtida. Vale um cuidado final: esses coeficientes falam de associação, não de causa; a leitura deve ficar no plano associativo, sem saltar para conclusões causais (Shmueli, 2010). Entendida assim, a interpretabilidade une transparência e responsabilização, transformando uma escolha de método em salvaguarda ética.

7 MATRIZ DE RISCOS E MITIGAÇÕES DO PIPELINE PREDITIVO PARA ESTIMATIVA DE QVT

O Quadro 1 reúne a análise: para cada etapa do pipeline preditivo, o risco ético predominante e a mitigação correspondente, com o dispositivo da LGPD pertinente.

Etapa	**Risco ético**	**Mitigação (fundamento)**
Coleta	Consentimento fragilizado pela assimetria de poder; coleta excessiva; reuso dos dados com outra finalidade (avaliação de desempenho, desligamentos).	Base legal adequada (art. 7º, IV; art. 11, II, "c"); TCLE em linguagem acessível como salvaguarda ética (Res. CNS 466/2012 e 510/2016); vinculação à finalidade (art. 6º, I); minimização, com instrumentos validados de escore global; terceiro independente na aplicação.
Armazenamento	Reidentificação; acesso indevido a dados potencialmente sensíveis.	Anonimização/pseudonimização; controle de acesso; segurança da informação (arts. 11 e 46).
Pré-processamento	Introdução/ampliação de vieses por exclusão de casos, imputação e padronização; base não representativa.	Documentação das decisões de tratamento, em atenção à prestação de contas (art. 6º, X, da LGPD); verificação de representatividade da amostra, em observância à qualidade dos dados e à não discriminação (art. 6º, V e IX; Barocas & Selbst, 2016).
Modelagem	Opacidade; redução do construto subjetivo a escore (validade de medida); desempenho desigual entre grupos.	Modelos lineares interpretáveis por construção (Rudin, 2019); instrumentos validados; avaliação de erro desagregada por subgrupos (sexo, setor, vínculo), em observância à não discriminação (art. 6º, IX; Mehrabi et al., 2021
Interpretação	Atribuição causal indevida; instabilidade dos coeficientes sob colinearidade; estimativa tomada como veredito; uso punitivo.	Leitura associativa, não causal (Shmueli, 2010); análise de estabilidade dos coeficientes (bootstrap) e Elastic Net sob preditores correlacionados (Zou & Hastie, 2005); comunicação da estimativa como aproximação, em atenção à transparência (art. 6º, VI, da LGPD).
Uso	Decisões que prejudiquem o trabalhador; reidentificação de equipes pequenas em relatórios gerenciais.	Uso agregado e formativo, com número mínimo de respondentes por recorte; governança e supervisão humana; revisão de

		decisões automatizadas, quando cabível (art. 20).

Quadro 1 — Matriz de riscos éticos e mitigações por etapa do pipeline preditivo de QVT
Fonte: elaboração própria (2026).

Três leituras transversais emergem da matriz. A primeira é que os riscos de maior gravidade se concentram nas extremidades do pipeline, coleta e uso, justamente as etapas em que as decisões são humanas e institucionais, e não algorítmicas. Isso desloca o centro do debate: a ética da predição de QVT é menos uma "ética do algoritmo" e mais uma ética da governança que o envolve, o que converge com a crítica de Gal et al. (2020) ao tecnocentrismo do campo.

A segunda leitura é a complementaridade entre mitigações técnicas e institucionais. Anonimização, modelos interpretáveis e verificação de representatividade são condições necessárias, mas insuficientes: sem as salvaguardas institucionais, terceiro independente, governança, supervisão humana, limites de agregação, as proteções técnicas podem ser contornadas na prática. A matriz sugere, portanto, que nenhuma célula opera isoladamente; mitigação ética é propriedade do arranjo, não de uma técnica.

A terceira leitura diz respeito à interdependência entre etapas. Um viés não mitigado no pré-processamento contamina a interpretação dos coeficientes na etapa seguinte e, por consequência, o uso; do mesmo modo, uma coleta excessiva amplia os riscos de todas as etapas posteriores. A matriz deve, assim, ser lida como instrumento dinâmico de governança do pipeline, orientando decisões antes que os riscos se propaguem, e não como checklist estático de conformidade. Dessa forma, ela constitui um instrumento orientador para a implementação de soluções preditivas que conciliem desempenho analítico, responsabilidade ética e conformidade regulatória.

8 CONSIDERAÇÕES FINAIS

Ao longo do texto, procurou-se mostrar que, quando se prediz a QVT a partir de dados de pessoas, a ética deve fazer parte do desenho do pipeline. Defendeu-se, ainda, que a interpretabilidade do modelo, sustentada por algoritmos lineares regularizados e pela leitura dos coeficientes Beta padronizados, funciona como exigência ética: é ela que torna auditável a produção das estimativas, concretiza os princípios de transparência e prestação de contas e operacionaliza, quando cabível, o direito de revisão de decisões automatizadas.

Um pipeline preditivo de QVT só se justifica se estiver a serviço de melhorar as condições de trabalho, e não de vigiar ou classificar pessoas. Vale reconhecer os limites deste trabalho: seu caráter teórico, que deixa à aplicação em campo a verificação de se as salvaguardas propostas bastam, inclusive quanto ao grau em que os próprios trabalhadores compreendem o consentimento e a finalidade do tratamento, e a ausência de revisão sistemática da literatura, caminho que estudos futuros podem percorrer para testar a abrangência das categorias aqui propostas.

REFERÊNCIAS

Barocas, S., & Selbst, A. D. (2016). Big data's disparate impact. *California Law Review, 104*(3), 671-732. https://doi.org/10.15779/Z38BG31

Brasil. Conselho Nacional de Saúde. (2012). *Resolução nº 466, de 12 de dezembro de 2012*: aprova as diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos. https://www.gov.br/conselho-nacional-de-saude/pt-br/acesso-a-informacao/atos-normativos/resolucoes/2012/resolucao-no-466.pdf/view

Brasil. Conselho Nacional de Saúde. (2016). *Resolução nº 510, de 7 de abril de 2016*: dispõe sobre as normas aplicáveis a pesquisas em Ciências Humanas e Sociais. https://conselho.saude.gov.br/resolucoes/2016/Reso510.pdf

Brasil. (2018). *Lei nº 13.709, de 14 de agosto de 2018*: Lei Geral de Proteção de Dados Pessoais (LGPD). https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm

Ferreira, M. C. (2011). *Qualidade de vida no trabalho: uma abordagem centrada no olhar dos trabalhadores*. Ergopublic. https://ergopublic.com.br/arquivos/1359392512.36-arquivo.pdf

Floridi, L., & Taddeo, M. (2016). What is data ethics? *Philosophical Transactions of the Royal Society A, 374*(2083). https://doi.org/10.1098/rsta.2016.0360

Gal, U., Jensen, T. B., & Stein, M.-K. (2020). Breaking the vicious cycle of algorithmic management: a virtue ethics approach to people analytics. *Information and Organization, 30*(2), 100301. https://doi.org/10.1016/j.infoandorg.2020.100301

Garbaccio, G. L., & Kischelewski, F. L. N. (2024). Governança e boas práticas na Lei Geral de Proteção de Dados por meio da conformidade, da gestão de riscos e da accountability. *Revista Brasileira de Estudos Políticos*, (128), 155-195. https://doi.org/10.9732/2024.V128.894

Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: biased estimation for nonorthogonal problems. *Technometrics, 12*(1), 55-67. https://doi.org/10.1080/00401706.1970.10488634

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: with applications in R* (2nd ed.). Springer. https://www.statlearning.com/

Jobin, A., Ienca, M., & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence, 1*(9), 389-399. https://doi.org/10.1038/s42256-019-0088-2

Limongi-França, A. C. (2004). *Qualidade de vida no trabalho — QVT: conceitos e práticas nas empresas da sociedade pós-industrial* (2ª ed.). Atlas.

Mehrabi, N., et al. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys, 54*(6), Artigo 115, 1-35. https://doi.org/10.1145/3457607

Meneghetti, F. K. (2011). O que é um ensaio-teórico? *Revista de Administração Contemporânea, 15*(2), 320-332. https://doi.org/10.1590/S1415-65552011000200010

Mittelstadt, B. D., et al. (2016). The ethics of algorithms: mapping the debate. *Big Data & Society, 3*(2). https://doi.org/10.1177/2053951716679679

Molnar, C. (2022). *Interpretable machine learning: a guide for making black box models explainable* (2nd ed.). Independently published. https://christophm.github.io/interpretable-ml-book/

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence, 1*(5), 206-215. https://doi.org/10.1038/s42256-019-0048-x

Saltz, J. S., & Shamshurin, I. (2016). Big data team process methodologies: a literature review and the identification of key factors for a project's success. In *2016 IEEE International*

Conference on Big Data (pp. 2872-2879). IEEE. https://doi.org/10.1109/BigData.2016.7840936

Shmueli, G. (2010). To explain or to predict? *Statistical Science, 25*(3), 289-310. https://doi.org/10.1214/10-STS330

Tibshirani, R. (1996). Regression shrinkage and selection via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological), 58*(1), 267-288. https://doi.org/10.1111/j.2517-6161.1996.tb02080.x

Tursunbayeva, A., Di Lauro, S., & Pagliari, C. (2018). People analytics — a scoping review of conceptual boundaries and value propositions. *International Journal of Information Management, 43*, 224-247. https://doi.org/10.1016/j.ijinfomgt.2018.08.002

Tursunbayeva, A., Pagliari, C., Di Lauro, S., & Antonelli, G. (2021). The ethics of people analytics: risks, opportunities and recommendations. *Personnel Review, 51*(3), 900-921. https://doi.org/10.1108/PR-12-2019-0680

Walton, R. E. (1973). Quality of working life: what is it? *Sloan Management Review, 15*(1), 11-21. https://www.academia.edu/2085254/Quality_of_working_life_what_is_it

Zou, H., & Hastie, T. (2005). Regularization and variable selection via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology), 67*(2), 301-320. https://doi.org/10.1111/j.1467-9868.2005.00503.x