

Capacitação de profissionais para a Indústria 4.0: Evidências preliminares de eficiência do curso InData

Felipe Leite Lobo, DCC, Universidade Federal de Roraima (UFRR),
felipe.lobo@ufrr.br, <https://orcid.org/0000-0002-9716-9384>

Marcelo Henrique Oliveira Henklain, DCC, Universidade Federal de Roraima (UFRR),
marcelo.henklain@ufrr.br, <https://orcid.org/0000-0001-9884-8592>

Marcelle Alencar Urquiza, DCC, Universidade Federal de Roraima (UFRR),
marcelle.urquiza@ufrr.br, <https://orcid.org/0000-0001-9102-8751>

Acauan Cardoso Ribeiro, DCC, Universidade Federal de Roraima (UFRR),
acauan.ribeiro@ufrr.br, <https://orcid.org/0000-0002-3462-5100>

Luciano Ferreira Silva, DCC, Universidade Federal de Roraima (UFRR),
luciano.silva@ufrr.br, <https://orcid.org/0000-0003-1743-4932>

Leandro Nelinho Balico, DCC, Universidade Federal de Roraima (UFRR),
leandro.balico@ufrr.br, <https://orcid.org/0000-0003-4022-460X>

Resumo. O objetivo deste estudo foi avaliar a eficiência do curso InData em relação ao ensino do comportamento geral de “desenvolver soluções tecnológicas no campo da Ciência de Dados e Aprendizado de Máquina para problemas da Indústria 4.0”. Participaram 78 estudantes do ensino superior. Na comparação entre pré e pós-teste, identificamos diferenças estatisticamente significativas e com tamanho do efeito elevado, mostrando que desempenho e autoconfiança nas próprias respostas melhoraram entre início e fim do curso. Em conjunto com as notas dos projetos finais, esses resultados sugerem que ocorreu aprendizado. Dados de satisfação mostraram que os alunos apreciaram o curso. Esperamos com este estudo incentivar mais pesquisas sobre formação de profissionais para a Indústria 4.0.

Palavras-chave: Educação em computação; Formação profissional; Indústria 4.0.

Training Professionals for Industry 4.0: Evidence of the InData Course's Efficiency

Abstract. The objective of this study was to evaluate the efficiency of the InData course in teaching the general behavior of "developing technological solutions in the field of Data Science and Machine Learning for Industry 4.0 problems". A total of 78 higher education students participated. Comparing pre- and post-test results, we identified statistically significant differences with a high effect size, indicating that both performance and self-confidence in their responses improved from the beginning to the end of the course. Along with the final project grades, these results suggest that learning took place. Satisfaction data showed that students appreciated the course. With this study, we hope to encourage further research on training professionals for Industry 4.0.

Key words: Computer education; Professional training; Industry 4.0.

1. Introdução

A integração de tecnologias digitais e físicas associada à globalização forneceu as bases para o advento da Indústria 4.0 (LEMSTRA; MESQUITA, 2023). Essa quarta revolução industrial pode levar a produtos de melhor qualidade, com menor custo e maior personalização (MASOOD; SONNTAG, 2020). Contudo, para que se concretize, um dos desafios existentes é a formação de profissionais qualificados para atuar nessa indústria (HERNANDEZ-DE-MENENDEZ et al., 2020; JAN et al., 2023).

Por essa razão, o nosso objetivo neste estudo foi avaliar a eficiência do curso InData em relação ao ensino do comportamento geral de “desenvolver soluções tecnológicas no campo da Ciência de Dados e Aprendizado de Máquina para problemas da Indústria 4.0”. Para alcançar esse objetivo, buscamos responder a três perguntas: PP01. Existem evidências de que ocorreu aprendizado nos dois módulos do curso, considerando os comportamentos-objetivo propostos? PP02. Existem evidências de que houve aumento de autoconfiança em relação às próprias respostas nos testes do curso? PP03. Existem evidências de que a experiência no curso foi satisfatória para os alunos?

2. Fundamentação teórica

2.1. Conceitos básicos sobre Indústria 4.0

A quarta revolução industrial representa uma nova forma de organizar o trabalho e a cadeia de produção, habilitando indústrias a responderem com maior efetividade às constantes demandas do mercado consumidor e mudanças no seu entorno. Essa nova organização requer a integração de tecnologias digitais e físicas, que viabilizem coletar e analisar dados para orientar a tomada de decisão e tornar a indústria o mais flexível e auto organizável possível (MASOOD; SONNTAG, 2020; LEMSTRA; MESQUITA, 2023). Algumas tecnologias são centrais nesse processo, tais como (1) sistemas ciberfísicos, (2) redes e internet das coisas, (3) cibersegurança e (4) inteligência artificial (TELLES et al., 2020; JAN et al., 2023).

Atualmente, a pesquisa aplicada sobre Indústria 4.0 ainda é escassa (LEMSTRA; MESQUITA, 2023) pelos desafios que essa revolução enfrenta. Um deles é a falta de clareza sobre como incorporar as tecnologias ao processo produtivo existente (SUPTITZ et al., 2017), principalmente, no caso de pequenas e médias empresas (MASOOD; SONNTAG, 2020). Outro é a escassez de profissionais qualificados para atuar nessa nova indústria (JAN et al., 2023). Esse é o desafio com o qual lidamos no presente trabalho.

2.2. Ensino-aprendizagem para profissionais da Indústria 4.0

Neste estudo adotamos a perspectiva da Análise do Comportamento, ciência que estuda o comportamento humano e que tem sido bem-sucedida em suas aplicações ao contexto educacional (KIENEN et al., 2021). O comportamento é definido como um sistema de interações entre o ambiente que antecede as ações de uma pessoa, as próprias ações e o ambiente subsequente a essas ações (CORTEGOSO; COSER, 2023). Ambiente é tudo o que estabelece uma relação de interdependência com uma ação. Ação, por sua vez, envolve desde sentimentos e processos cognitivos até condutas publicamente observáveis (CORTEGOSO; COSER, 2023).

O que ensinamos como educadores não são conhecimentos, mas comportamentos orientados por conhecimentos. Tais comportamentos devem habilitar o aprendiz a lidar de modo mais efetivo com a sua realidade (KIENEN et al., 2021). O trabalho de ensinar, portanto, significa arranjar condições sob as quais os alunos aprendem um ou mais comportamentos. Aprender, por sua vez, consiste em modificação duradoura no repertório do aluno, seja por aquisição ou aperfeiçoamento de um comportamento. O trabalho do educador começa, então, pela proposição dos comportamentos que devem ser ensinados (KIENEN et al., 2021), os quais podem ser chamados de comportamentos-objetivo. A proposição de comportamentos-objetivo, tipicamente, requer um processo de decomposição no qual o professor identifica o comportamento-objetivo mais geral e, gradualmente, vai descobrindo comportamentos-objetivo constituintes do mais geral.

Até o momento, ainda não existe consenso na literatura sobre quais são os comportamentos-objetivo que devem ser ensinados para profissionais atuarem na Indústria 4.0 (HERNANDEZ-DE-MENENDEZ et al., 2020). É conhecido que esse repertório deve ser composto por capacidades técnicas (e.g., programação), metodológicas (e.g., habilidades de pesquisa), sociais (e.g., habilidades com linguagem) e pessoais (e.g., habilidade para trabalhar em situações de estresse) (LEMSTRA; MESQUITA, 2023). Neste estudo, trataremos apenas do ensino de capacidades técnicas, especificamente, relacionadas aos campos da Ciência de Dados e Inteligência Artificial.

Por fim, cumpre esclarecer que o aprendizado de um modo geral e, particularmente, de capacidades técnicas, como programar computadores, acontece quando a apresentação de uma ação é regularmente seguida por reforço (CORTEGOSO; COSER, 2023). É reforçador todo o ambiente subsequente a ação de uma pessoa que a torna mais forte e provável de recorrer no futuro. Tal probabilidade de recorrência é esperada em ambientes antecedentes de algum modo relacionados àquele no qual a ação foi reforçada, o que, em contexto educacional, ocorre enquanto o ensino está em curso. Como decorrência dessa relação de reforçamento de uma ação, é esperado desde o aperfeiçoamento dessa ação, caso já tivesse sido adquirida, até a instalação dela no repertório da pessoa, caso o aluno não soubesse como apresentá-la quando o ensino começou. Além de aquisição ou aperfeiçoamento do repertório, é esperado que o aprendiz se sinta mais autoconfiante em relação ao que aprendeu, quando comparamos como se sentia quando o ensino começou. É, ainda, fundamental que o aluno vivencie a aprendizagem como uma experiência gratificante no sentido de sentir-se inclinado a seguir estudando (KIENEN et al., 2021). Por essa razão, neste estudo criamos uma medida de aprendizagem, uma de autoconfiança em relação ao que foi ensinado e uma de satisfação com a experiência de ensino a qual o aluno foi exposto.

3. Trabalhos relacionados

Estudos evidenciam a necessidade de pesquisas sobre formação profissional para a Indústria 4.0. Além disso, sugerem o que deve ser contemplado nesse ensino e como ele deve ser conduzido. Uma preocupação central na literatura científica é o que precisa ser ensinado. Hernandez-de-Menendez et al. (2020), por exemplo, caracterizaram competências que profissionais necessitam para atuar na Indústria 4.0. Os achados desse estudo sugerem que não existe consenso em relação a quais competências são necessárias, mas algumas parecem ser comumente citadas, tais como: (1) usar tecnologias necessárias para a Indústria 4.0 (e.g., robôs e Inteligência Artificial), (2) conduzir análises de dados e (3) aplicar conhecimento que agregue valor colaborativamente em vários domínios.

Nessa mesma linha de pesquisa, Ferreira e Oliveira (2023) identificaram a partir de uma revisão da literatura impactos da Indústria 4.0 para a educação e examinaram quais habilidades serão requisitadas dos profissionais para que atuem nessa indústria. Verificou-se que pensamento crítico e solução criativa de problemas, colaboração e aprendizagem contínua são habilidades fundamentais. Tal como no estudo de Hernandez-de-Menendez et al. (2020), não foi possível chegar a uma lista exaustiva de habilidades.

Além de pesquisar sobre o que deve ser ensinado, estudos também propõem ou investigam como esse ensino deve ocorrer. Ekong et al. (2022), por exemplo, desenvolveram e testaram com sucesso um *framework* de capacitação de profissionais para a Indústria 4.0. Esse framework foi proposto com cinco elementos: (1) Identificação de habilidades necessárias para atuação na Indústria 4.0, o que pode ser feito por meio de pesquisa com empresas e entrevista com especialistas; (2) Desenvolvimento de projetos de aprendizagem que simulem problemas reais da Indústria 4.0; (3) Implementação de

metodologias de aprendizagem experiencial; (4) Avaliação do aprendizado, para garantir que os alunos estão atingindo os objetivos dos projetos; e (5) Melhoria contínua a partir de feedbacks dos alunos, de professores e empresas.

May et al. (2022), por sua vez, avaliaram uma abordagem experiencial para o ensino de Aprendizado de Máquina em cursos de engenharia de produção. Os pesquisadores criaram uma metodologia prática que permitisse o uso do conhecimento adquirido em situações reais da Indústria 4.0. Eles reportaram que o ensino foi bem-sucedido, mas não forneceram detalhes sobre a aprendizagem dos alunos, aspecto que também não foi abordado em profundidade na pesquisa de Ekong et al. (2022).

Em síntese, notamos a necessidade de mais estudos que caracterizem os comportamentos que precisam ser ensinados para profissionais da Indústria 4.0 e que desenvolvam o ensino desse repertório por meio de condições que simulem problemas reais que o profissional irá vivenciar em sua realidade laboral. Assim, neste estudo exploratório, o nosso objetivo foi avaliar a eficiência do curso InData em relação ao ensino do comportamento geral de “desenvolver soluções tecnológicas no campo da Ciência de Dados e Aprendizado de Máquina para problemas da Indústria 4.0”.

4. Método

4.1. O projeto InData

A Capacitação em Inteligência Artificial e Ciência de Dados Aplicadas à Indústria 4.0, designada de InData, consistiu em um curso composto por dois módulos, cada um de 20h. O curso foi aberto para estudantes de nível superior, independente de área. Por essa razão, o Módulo 1 teve a finalidade de ensinar conceitos básicos sobre Indústria 4.0, Ciência de Dados, programação e Inteligência Artificial. O Módulo 2 foi prático, sendo orientado para o aprendizado de três técnicas de IA que permitissem a realização de projeto simulando situação real da Indústria 4.0, a saber: criação de modelo de classificação, regressão ou agrupamento em relação a uma base com dados da indústria. Participaram da equipe do curso cinco docentes. Consulte neste link < <http://dx.doi.org/10.13140/RG.2.2.13278.34882> > os 56 comportamentos-objetivo (COs) propostos para o curso InData.

No Módulo 1, as disciplinas foram: (1ª) Ciência de Dados aplicada à Indústria 4.0 (Modalidade: EAD; Duração: 2,5h; Docente: D1; COs: 9); (2ª) Noções de Estatística para Ciência de Dados (Modalidade: EAD; Duração: 2,5h; Docente: D2; COs: 7); (3ª) Noções de programação para Ciência de Dados (Modalidade: EAD; Duração: 10h; Docente: D3; COs: 12); e (4ª) Introdução à Inteligência Artificial (Modalidade: EAD; Duração: 2,5h; Docente: D4; COs: 14). No Módulo 2, as disciplinas foram: (1ª) Árvore de decisão e Floresta Aleatória para problemas de classificação da Indústria 4.0 (Modalidade: EAD; Duração: 5h; Docente: D3; COs: 6); (2ª) Árvore de decisão e Floresta Aleatória para problemas de regressão da Indústria 4.0 (Modalidade: EAD; Duração: 5h; Docente: D2; COs: 6); (3ª) K-means para problemas de clusterização da Indústria 4.0 (Modalidade: EAD; Duração: 5h; Docente: D4; COs: 3); e (4ª) Supervisão de projetos (Modalidade: Presencial; Duração: 5h; Docente: D1 e D5; Cos: Todos).

Os COs foram numerados de modo a indicar o seu grau de especificidade. Assim, ‘1.1.’ é o comportamento que foi decomposto diretamente a partir do comportamento geral, enquanto ‘1.1.1.’ foi decomposto a partir do 1.1. Os COs das Disciplinas de 1 a 4, do Módulo 1, são aqueles iniciados por ‘1.’, ‘2.’, ‘3.’ e ‘4.’, respectivamente. Os COs das disciplinas do Módulo 2 são indicados, respectivamente, por ‘5.’, ‘6.’ e ‘7.’. Elegemos

apenas um exemplo de CO de cada disciplina por economia de espaço: “1.4. Identificar as tecnologias mais empregadas na Indústria 4.0”; “2.1.1. Caracterizar recursos da estatística descritiva para criação de modelos”; “3.3. Escrever programas em Python para uso no âmbito da Ciência de Dados”; “4.1.1. Identificar usos do Aprendizado de Máquina na Ciência de Dados e suas aplicações na Indústria 4.0”; “5.2. Implementar árvore de decisão para solução de problema de classificação com o Scikit Learn”; “6.2. Implementar árvore de decisão para solução de problema de regressão com o Scikit Learn”; e “7.2. Implementar a técnica de k-means para solução de problema de clusterização com o Scikit Learn”.

A partir desses objetivos, foram criados instrumentos avaliativos e, depois, cada professor criou slides para as suas disciplinas, os quais foram disponibilizados para os demais professores validarem. Com os slides validados, os professores gravaram videoaulas, as quais foram editadas e armazenadas no YouTube, sendo que os links foram disponibilizados em uma sala do Moodle construída para o curso. Nesta sala virtual, o curso foi organizado com uma estrutura na qual o cumprimento de uma tarefa era pré-requisito para que a próxima fosse liberada. A primeira tarefa era responder ao pré-teste do Módulo 1, sendo seguido pela primeira disciplina. Cada disciplina tinha um conjunto de videoaulas seguidas por uma atividade avaliativa com função de treinamento dos comportamentos-objetivo. Essa atividade podia ser repetida quantas vezes fossem necessárias, mas era preciso atingir 100% de acertos para avançar. Ao final das quatro disciplinas desse módulo, o aluno respondia a um pós-teste e a uma avaliação de satisfação do módulo. O Módulo 2 teve a mesma dinâmica, sendo que criamos um pré e pós-teste para cada disciplina de modo a reduzir o tamanho da tarefa, evitando acumular todos os itens de uma disciplina em um único pré e pós-teste.

Foram ofertadas duas turmas do curso em 2024. A primeira entre agosto e outubro e a segunda entre outubro e dezembro. Além dos professores, a equipe do curso foi composta por seis alunos, que forneceram apoio operacional ao longo do projeto. Uma de suas principais atividades foi monitorar a evolução dos alunos no curso, mandando mensagens por WhatsApp para verificar motivos de atrasos na realização de tarefas e combinar novas datas para a conclusão dessas atividades. Após as inscrições, foi realizada uma live de abertura do curso para cada turma, na qual instruções eram fornecidas sobre o seu funcionamento. Criamos também um grupo no WhatsApp para apoio aos alunos, além do fórum de dúvidas no Moodle. Ao final de cada oferta do curso foi realizada live de encerramento com premiação dos melhores trabalhos.

4.2. Participantes

Participaram 78 pessoas com média de idade de 23,26 anos ($DP = 4,79$), variando de 18 a 40, sendo 55 da primeira turma e 23 da segunda; 67% e 61%, respectivamente, finalizaram os dois módulos do curso. Em nossa amostra, 80,77% das pessoas declararam ser do sexo masculino, 60,26% eram pretos ou pardos, 94,87% reportaram não ter deficiência e 79,49% eram da área de “Ciências Exatas, da Terra e Engenharias”, dos quais 75,64% eram de cursos de Informática. Todas assinaram o Termo de Consentimento Livre e Esclarecido, autorizando a participação neste estudo.

4.3. Instrumentos

Na fase de inscrições, coletamos os seguintes dados sociodemográficos: idade, sexo, identidade étnico racial, se a pessoa tinha algum tipo de deficiência (visual, auditiva, física, intelectual e/ou psicossocial). Para uso durante a capacitação, criamos três instrumentos relativos a cada módulo: (1) Pré-teste, cuja finalidade era avaliar, antes do

ensino, em que medida o aluno já havia desenvolvido os comportamentos-objetivo; (2) Pós-teste, cuja função era avaliar em que medida o aluno adquiriu ou aperfeiçoou os comportamentos-objetivo; (3) Treino, que tinha a finalidade de ajudar o aluno a avaliar o seu desempenho e praticar o desenvolvimento dos comportamentos-objetivo.

Esses instrumentos foram construídos a partir da lista de comportamentos-objetivo previamente definida pelo grupo de professores para orientar o trabalho nesta capacitação. Com base nessa lista e em 16 diretrizes para a redação de itens, os professores construíram 30 itens de verdadeiro ou falso para cada módulo relacionados aos comportamentos-objetivo das disciplinas com as quais iriam trabalhar, bem como redigiram justificativas para os gabaritos. Em seguida, o coordenador pedagógico (D5) avaliou cada item. Quando algum problema era identificado, o professor que construiu o item era solicitado a revisá-lo. Após a aprovação do coordenador, o item passava pela avaliação dos outros três docentes, que examinavam cada item em relação a três perguntas a partir de escala Likert de intensidade, “1 – Pouquíssima” a “5- Muitíssima”: (1) clareza da linguagem do item - “O item está escrito de modo compreensível para os alunos que irão respondê-lo?”; (2) Pertinência prática - “O que o item avalia é pertinente que os alunos saibam?”; (3) Relevância teórica - “O conteúdo deste item é relevante em relação ao conhecimento básico que os alunos devem aprender sobre Ciência de Dados e IA Aplicadas à Indústria 4.0?”. Caso algum professor identificasse problema no item, poderia atribuir pontuação baixa e deixar comentário para que ele fosse aperfeiçoado. Por fim, calculamos o Coeficiente de Validade de Conteúdo (CVC), adotando o critério de que o instrumento deveria pontuar acima de 0,8 em clareza, pertinência e relevância para ser aprovado (HERNANDEZ-NIETO, 2002), podendo ter itens com pontuações menores, desde que tivessem sido aperfeiçoados com base nos comentários deixados pelos professores. Os itens estão disponíveis neste link < <http://dx.doi.org/10.13140/RG.2.2.13278.34882> >.

Pré-teste e Pós-teste. Foram construídos 40 itens de verdadeiro ou falso para o pré-teste do Módulo 1, sendo 10 referentes aos comportamentos-objetivo de cada uma das quatro disciplinas desse módulo. O CVC de clareza desse teste foi de 0,89 e o de pertinência e relevância foi 0,90. Construímos a mesma quantidade de itens para o pós-teste desse módulo, sendo o CVC de clareza e de pertinência 0,96 e o de relevância 0,95. Para o pré-teste do Módulo 2 foram construídos 30 itens (10 para cada uma das três disciplinas). O CVC de clareza desse pré-teste foi 0,92, o de pertinência foi 0,95 e o de relevância foi 0,96. O pós-teste desse módulo teve essa mesma extensão e o CVC de clareza foi 0,91, o de pertinência foi 0,94 e o de relevância foi 0,95. Todos esses itens foram respondidos em uma escala de quatro pontos, “1 – Totalmente seguro de que a afirmação é Falsa”, “2 – Parcialmente seguro de que a afirmação é Falsa”, “3 – Parcialmente seguro de que a afirmação é Verdadeira” e “4 – Totalmente seguro de que a afirmação é Verdadeira”. Por meio dessa medida, conseguimos avaliar se acertos e autoconfiança nas respostas fornecidas mudaram entre o início e o final do curso.

Itens de treino. Foram construídos 40 itens para o Módulo 1, sendo 10 para cada disciplina. O CVC de clareza, pertinência e relevância foi de 0,95. Para o Módulo 2, foram desenvolvidos 30 itens, cuja clareza, pertinência e relevância apresentaram CVCs de 0,95. Esses itens foram respondidos apenas com as opções Verdadeiro ou Falso.

Escala de Satisfação (ESAT). Mediante autorização das autoras, foi ajustada para as necessidades deste estudo a partir da seleção de itens da Escala de Satisfação com a Experiência Acadêmica (ESEA, desenvolvida por Schleich et al., 2006). Continha 15 itens (consultar: <http://dx.doi.org/10.13140/RG.2.2.25656.52483>), respondidos segundo uma escala Likert: “1 = Nada Satisfeito” a “5 = Totalmente Satisfeito”. Não existem

estudos psicométricos da ESAT, mas consideramos que mensure satisfação com a infraestrutura do curso (ambiente virtual de aprendizagem, recursos pedagógicos e suporte às dúvidas), satisfação com o curso (qualidade dos professores) e satisfação com oportunidades de desenvolvimento profissional e pessoal.

4.4. Procedimento de coleta e análise de dados

A coleta de dados ocorreu à medida que o curso foi realizado, a partir dos instrumentos previamente cadastrados no Moodle. A análise desses dados envolveu o cálculo de estatísticas descritivas e do teste de postos com sinais de Wilcoxon para amostras pareadas, para comparação dos dados de pré e pós-teste. Para calcular a nota de acertos no pré ou pós-teste, tratamos respostas 1 e 2 como correspondentes a opção “falso” e respostas 3 e 4 como correspondentes a opção “verdadeiro”. Verificávamos, então, quantos acertos foram obtidos comparando respostas aos gabaritos. No caso dos itens de treino, havia apenas as opções tradicionais de resposta, “verdadeiro” ou “falso”, sendo direto o cálculo de acertos. O cálculo de autoconfiança, por sua vez, consistiu na somatória de respostas 1 e 4, divididas pelo total de itens do teste, o que gerava um percentual de respostas de total segurança. Por fim, no cálculo de satisfação adotamos uma média aritmética para gerar um escore capaz de resumir as avaliações de cada aluno aos 15 itens da ESAT. Neste estudo, assumimos o valor de corte de 0,2 para o tamanho do efeito estimado pela correlação ponto bisserial como indicativo de sucesso. Esse critério é uma aproximação do d de Cohen de 0,4 sugerido por Hattie (2015).

5. Resultados e Discussão

5.1. Existem evidências de que ocorreu aprendizado nos dois módulos, considerando os comportamentos-objetivo propostos?

A Tabela 1 apresenta a média de notas dos alunos nas listas de 10 exercícios criadas para cada uma das sete disciplinas do curso. Esses dados foram calculados a partir das primeiras notas que os alunos obtiveram nos exercícios, pois as últimas eram necessariamente 10, afinal este era um pré-requisito para o aluno progredir no curso.

Tabela 1. Média de notas nos exercícios das disciplinas.

Turma	Média (Desvio padrão) de Notas nos exercícios							
	Módulo 1 - Disciplinas				Módulo 2 - Disciplinas			
	1	2	3	4	1	2	3	
1	9,13 (1,06)	9,09 (1,28)	8,22 (1,75)	8,47 (1,87)	8,74 (1,50)	8,83 (1,77)	9,26 (1,38)	
2	9,35 (0,88)	9,26 (1,01)	7,87 (1,63)	8,09 (2,09)	8,50 (1,87)	9,00 (1,57)	9,21 (1,19)	
Todas	9,19 (1,01)	9,14 (1,20)	8,12 (1,71)	8,36 (1,93)	8,67 (1,60)	8,88 (1,70)	9,24 (1,32)	

Com relação às primeiras notas obtidas em cada uma das sete listas de exercícios, observamos que não ocorreram pontuações abaixo de 7,00. Isso sugere que os alunos possam ter aprendido os comportamentos-objetivo a partir das videoaulas às quais foram expostos. Essa interpretação é fortalecida pelos dados de tentativas para atingir 100% de acertos. Em média, os alunos conseguiram alcançar o critério com até 2 tentativas, ou seja, rapidamente. Isso sugere que haviam adquirido o repertório necessário para responder as questões da lista de exercícios, o que deve ter ocorrido em função das aulas.

A Tabela 2 exibe as médias e desvios padrão das notas dos alunos no pré e pós-teste, bem como as diferenças entre essas avaliações. Podemos notar que para as duas turmas do curso, assim como no geral, os resultados evidenciaram ganhos, sendo que a Turma 1 foi a que mais melhorou o seu desempenho, com ganho de 1,25 no Módulo 1 e 1,56 no Módulo 2, em relação a 0,71 e 1,02, respectivamente, no caso da Turma 2. Nos

Módulos 1 ($z = 5,704$; $p < ,001$; $r_{pb} = 0,779$) e 2 ($z = 5,320$; $p < ,001$; $r_{pb} = 0,942$), as diferenças encontradas foram estatisticamente significativas e com elevado tamanho do efeito. O Módulo 2 foi o que gerou mais impacto. Com base na teoria analítico-comportamental, esses dados sugerem que ocorreu aprendizagem (CORTEGOSO; COSER, 2023), provavelmente, no sentido de aperfeiçoamento de comportamentos já presentes no repertório dos alunos antes do curso.

Analizamos também os dados de pré e pós-teste em função de cada um dos comportamentos-objetivo. Notamos melhoras, mesmo que pequenas, em 85% dos comportamentos-objetivo do Módulo 1 e 83% do Módulo 2, sendo que nesse último módulo a média de pontos percentuais de melhora foi maior, 12,75%, quando comparado com apenas 3,14% de ganho no Módulo 1. Esse exame confirmou os achados com as estatísticas inferenciais em relação ao Módulo 2. Verificamos, ainda, que os comportamentos-objetivo do Módulo 1 com maior ganho foram: “2.1.1.2. Identificar finalidade e situações de aplicação de medidas de tendências central”, trabalhado na Disciplina 1; e “4.1.1.2.1. Diferenciar problemas de classificação, regressão e de clusterização”, trabalhado na Disciplina 4. Identificamos também casos em que não houve ganhos. Os piores resultados foram em relação a: “4.1.1.1. Definir o conceito da expressão aprendizado de máquina” e “4.1.2.2. Identificar a finalidade dos dados para teste”, ambos da Disciplina 4. No Módulo 2, os comportamentos-objetivo com maior ganho foram: “5.1. Descrever principais aspectos do algoritmo para criação de uma árvore de decisão no contexto de problemas de classificação” e “5.4. Descrever principais aspectos do algoritmo para criação de uma floresta aleatória no contexto de problemas de classificação”, ambos desenvolvidos na Disciplina 1. Os piores resultados foram: “6.5. Implementar floresta aleatória para solução de problema de regressão”, da Disciplina 2.

Tabela 2. Média de acertos no pré e pós-teste por módulo do curso.

Turma	Módulo 1			Módulo 2		
	Média (DP)		Diferença	Média (DP)		Diferença
	Pré	Pós		Pré	Pós	
1	6,98 (1,06)	8,23 (1,24)	1,25	7,52 (1,89)	9,08 (1,40)	1,56
2	7,54 (1,00)	8,25 (1,03)	0,71	8,29 (1,97)	9,31 (1,07)	1,02
Todas	7,14 (1,07)	8,23 (1,17)	1,09	7,73 (1,93)	9,14 (1,32)	1,41

Esses dados mostram que versões futuras do curso devem oferecer melhores condições para ensinar alunos a definir o que é aprendizado de máquina, assim como implementar a floresta aleatória, que, talvez, possa ser mais difícil para o aluno por ser menos simples de visualizar, quando comparada à árvore de decisão e aos agrupamentos gerados pela técnica de K-means. Uma estratégia para lidar com essa dificuldade seria ampliar as atividades práticas do curso para facilitar o entendimento sobre a aplicação de cada técnica em contextos reais (EKONG et al., 2022). Mesmo com aperfeiçoamentos sendo necessários, os dados das notas sugerem que o curso foi eficiente para a promoção de aprendizagens e, ao lado da intervenção de May et al. (2022), conta como mais uma experiência bem-sucedida de formação de profissionais para a Indústria 4.0.

Uma evidência importante de aprendizado foi o desenvolvimento dos projetos finais do curso, que consistiam em aplicar uma das três técnicas de IA ensinadas para resolver problema de classificação, regressão ou clusterização com base de dados relativa à indústria. Na Turma 1, dos 37 alunos que finalizaram o Módulo 2, 31 entregaram esse projeto, que foi solicitado em um notebook do Google Collab. Com base em critérios definidos de avaliação, avaliamos os projetos e notamos que 24 obtiveram nota maior que 7. A média geral foi de 7,52 ($DP = 2,27$). Na Turma 2, dos 14 concluintes do Módulo 2, 11 fizeram o projeto, sendo que 10 obtiveram nota maior do que 7. A média geral foi de

7,75 ($DP = 2,19$). Notamos que a maior parte dos projetos desenvolvidos atendiam a critérios mínimos de qualidade na aplicação de uma das três técnicas de IA a problema real da Indústria 4.0. Esse dado também sugere que houve aprendizado.

5.2. Existem evidências de que houve aumento de autoconfiança em relação às próprias respostas nos testes?

A Tabela 4 exibe média e desvio padrão e as diferenças entre pré e pós-teste para as pontuações de segurança nas próprias respostas. As diferenças foram todas positivas e, tal como a nota, maiores no caso da Turma 1: 20,59 no Módulo 1 e 22,43 no Módulo 2. As diferenças gerais encontradas nos Módulos 1 ($z = 5,505$; $p < ,001$; $r_{pb} = 0,732$) e 2 ($z = 4,773$; $p < ,001$; $r_{pb} = 0,826$) foram estatisticamente significativas e com elevado tamanho do efeito. Encontramos, portanto, mais uma evidência que sugere que o curso foi eficiente (KIENEN et al., 2021).

Tabela 4. Média de segurança nas próprias respostas aos itens do pré e do pós-teste.

Turma	Módulo 1			Módulo 2		
	Média (DP)		Diferença	Média (DP)		Diferença
	Pré	Pós		Pré	Pós	
1	50,82 (23,50)	71,41 (17,81)	20,59	44,86 (30,24)	67,30 (26,78)	22,43
2	55,43 (24,27)	64,57 (19,64)	9,13	59,29 (35,09)	69,29 (24,11)	10,00
Todas	52,18 (23,66)	69,39 (18,51)	17,21	48,82 (31,95)	67,84 (25,85)	19,02

5.3. Existem evidências de que a experiência foi satisfatória para os alunos?

Os menores valores de satisfação identificados, considerando os dois módulos, foram 3,40 no caso da Turma 1 e 3,07 no caso da Turma 2. Uma vez que o valor máximo da escala é cinco, notamos que mesmo as menores notas envolveram uma satisfação moderada a alta. Quando examinamos a média das Turmas 1 ($Média = 4,46$; $DP = 0,48$) e 2 ($Média = 4,35$; $DP = 0,47$) e a média geral ($Média = 4,43$; $DP = 0,48$), notamos que a satisfação com o curso foi muito próxima do nível “Totalmente satisfeito”. Quando analisamos as médias de satisfação por módulo, notamos que o Módulo 2 teve uma satisfação maior ($Média = 4,49$; $DP = 0,48$) que o 1 ($Média = 4,40$; $DP = 0,47$). Ambas, porém, foram elevadas e constituem uma evidência adicional de eficiência do curso.

5.4. Avaliação dos resultados e limitações do estudo

Um dos méritos deste curso, que consideramos ser responsável pelos bons resultados, reside no seu planejamento. Ele envolveu, inicialmente, a proposição de comportamentos-objetivo (COs) (CORTEGOSO; COSER, 2023) e a construção, seguindo boas práticas psicométricas de investigação de validade de conteúdo (CASSEP-BORGES et al., 2010), de instrumentos avaliativos orientados por esses COs. Esse processo envolveu a troca de informações e reflexões entre docentes, favorecendo a formação de consensos sobre as aprendizagens esperadas por meio do curso, atendendo ao chamado de Hattie (2015) por uma noção compartilhada de impacto. Em seguida, aulas e atividades foram desenvolvidas com base nesses COs, o que torna mais provável que eles sejam aprendidos (KIENEN et al., 2021) e pode explicar os resultados positivos.

Apesar de suas contribuições, este estudo possui limitações importantes que devem ser consideradas. A primeira consiste na simplicidade dos instrumentos avaliativos usados no pré e pós-teste, pois itens de verdadeiro ou falso podem não mensurar adequadamente os comportamentos-objetivo propostos. Não obstante, acreditamos que possam ser indicadores relacionados com o aprendizado desses comportamentos. Uma segunda limitação foi a homogeneidade da amostra, composta predominantemente por

estudantes de informática, o que impede a generalização dos resultados. Deve-se considerar, porém, que este é um estudo exploratório. Finalmente, é preciso lembrar que, embora os resultados tenham sido promissores, ainda não é possível afirmar com segurança que os efeitos observados se devem apenas à intervenção, pois outras variáveis podem ter influenciado os resultados. Essa dúvida poderia ser atenuada se tivéssemos avaliado também um grupo controle.

6. Conclusão

O objetivo deste estudo foi avaliar a eficiência do curso InData em relação ao ensino do comportamento geral de “desenvolver soluções tecnológicas no campo da Ciência de Dados e Aprendizado de Máquina para problemas da Indústria 4.0”. Verificamos evidências favoráveis de eficiência do curso em relação à promoção de aprendizagem, autoconfiança e satisfação.

Considerando as limitações examinadas, avaliamos que estudos futuros devem aperfeiçoar a descrição dos comportamentos-objetivo e desenvolver instrumentos mais robustos de medida, aplicando este curso para estudantes de outras áreas do conhecimento. Importa também conduzir pesquisas que adotem o grupo controle. Avaliamos, por fim, que este estudo contribuiu com a produção de recursos pedagógicos e a identificação de estratégias promissoras de ensino que podem ser examinadas com maior controle experimental em pesquisas futuras, favorecendo desse modo a formação de profissionais para a atuação na Indústria 4.0.

Agradecimento

O projeto a partir do qual este estudo foi derivado foi apoiado pela SUFRAMA, com recursos da Lei nº 8.387, de 23 de 1991, no âmbito do PPI-Indústria 4.0, coordenado pelo CITS-Amazônia, aprovado pelo CAPDA/SUFRAMA e executado pelo Departamento de Ciência da Computação - DCC/UFRR.

Declaração de Conflito de Interesses

Os autores declaram que não possuem conflitos de interesses relacionados à presente pesquisa. O financiamento recebido não condicionou ou interferiu na condução da coleta de dados ou na análise dos resultados.

Referências

- CASSEP-BORGES, V.; BALBINOTTI, M. A. A.; TEODORO, M. L. M. (2010). Tradução e validação de conteúdo: uma proposta para a adaptação de instrumentos. In: Pasquali, L. (Org.), *Instrumentação psicológica: Fundamentos e práticas*. Porto Alegre: Artmed.
- CORTEGOSO, A. L.; COSER, D. S. *Elaboração de programas de ensino: Material autoinstrutivo*. São Carlos: EdUFSCar, 2023.
- EKONG, J.; CHAUHAN, V.; OSEDEME, J.; NIKNAM, S.; NGUYEN, R. A framework for Industry 4.0 workforce training through project-based and experiential learning approaches. In: *ASEE 2022 Annual Conference & Exposition*, Minneapolis, Minnesota. Anais [...]. American Society for Engineering Education, p. 1-15, 2022. <https://doi.org/10.18260/1-2--40637>
- FERREIRA, A. B.; OLIVEIRA, S. L. S. O estado da arte sobre a Indústria 4.0: Uma busca por contribuições na área de ensino e aprendizagem. In: *Congresso sobre*

Tecnologias na Educação, 8, 2023, Santarém/PA. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, p. 21-30, 2023. <https://doi.org/10.5753/ctrle.2023.231483>

HATTIE, J. The Applicability of Visible Learning to Higher Education. *Scholarship of Teaching and Learning in Psychology*, v. 1, n. 1, p. 79-91, 2015. <https://doi.org/10.1037/stl0000021>

HERNANDEZ-DE-MENENDEZ, M.; MORALES-MENENDEZ, R.; ESCOBAR, C. A.; MCGOVERN, M. Competencies for Industry 4.0. *International Journal on Interactive Design and Manufacturing*, v. 14., p. 1511-1524, 2020. <https://doi.org/10.1007/s12008-020-00716-2>

HERNANDEZ-NIETO, R. *Contributions to statistical analysis*. Mérida: Los Andes University Press, 2002.

JAN, Z.; AHAMED, F.; MAYER, W.; PATEL, N.; GROSSMANN, G.; STUMPTNER, M.; KUUSK, A. Artificial intelligence for industry 4.0: Systematic review of applications, challenges, and opportunities. *Expert Systems with Applications*, v. 216, p. 1-21, 2023. <https://doi.org/10.1016/j.eswa.2022.119456>

KIENEN, N., PANOSSO, M. G., NERY, A. G. S., WAKU, I., CARMO, J. S. Contextualização sobre a Programação de Condições para Desenvolvimento de Comportamentos (PCDC): Uma experiência brasileira. *Perspectivas em Análise do Comportamento*, v. 12, n. 2, p. 360-390, 2021. <https://doi.org/10.18761/PAC.2021.jul110>

LEMSTRA, M. A. M. S.; MESQUITA, M. A. Industry 4.0: a tertiary literature review. *Technological Forecasting and Social Change*, v. 186, n. B, p. 1-11, 2023. <https://doi.org/10.1016/j.techfore.2022.122204>

MASOOD, T.; SONNTAG, P. Industry 4.0: Adoption challenges and benefits for SMEs. *Elsevier Computers in Industry*, v. 121, 103261, 2020. <https://doi.org/10.1016/j.compind.2020.103261>

MAY, M. C.; FRENZER, M.; LANZA, G. Teaching Machine Learning in learning factories with Industry 4.0 use-cases. In: 12th Conference on Learning Factories, 2022. <https://dx.doi.org/10.2139/ssrn.4071757>

SCHLEICH, A. L. R., POLYDORO, S. A. J., SANTOS, A. A. A. Escala de satisfação com a experiência acadêmica de estudantes do ensino superior. *Avaliação Psicológica*, v. 5, n. 1, p. 11-20, 2006. Disponível em: <https://bit.ly/433aiTu>

SUPTITZ, I. L.; FROZZA, R.; MOLZ, R. F. Estado da arte da indústria gaúcha referente ao uso de técnicas de inteligência artificial por meio de um survey. *Brazilian Journal of Information Systems*, v. 10, n. 3, p. 36-48, 2017. <https://doi.org/10.5753/wics.2020.11044>

TELLES, E. S.; BARONE, D. A. C.; DA SILVA, A. M. Inteligência Artificial no Contexto da Indústria 4.0. In: Workshop sobre as Implicações da Computação na Sociedade (WICS), 1, 2020, Cuiabá. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, p. 130-136, 2020. <https://doi.org/10.5753/wics.2020.11044>