

工程人工智能：框架、挑战及未来方向

Jay Lee, Hanqi Su*, Dai-Yan Ji, and Takanobu Minami

Center for Industrial Artificial Intelligence, Department of Mechanical Engineering,

A. James Clark School of Engineering, University of Maryland, College Park,

Maryland, United States of America

hanqisu@umd.edu

Abstract

在过去十年中,人工智能(AI)和机器学习(ML)在工程领域的应用得到了广泛的关注,展示了它们在数据驱动环境中的潜力。然而,工程问题的复杂性和多样性通常需要开发特定领域的人工智能方法,这些方法常常由于缺乏系统的方法论、可扩展性以及在开发过程中的鲁棒性而受到阻碍。为了解决这一差距,本文介绍了“ABCDE”作为工程AI的关键要素,并提出了一种统一的、系统的工程人工智能生态系统框架,包括八个基本层次,连同其属性、目标和应用,以指导特定工程需求的人工智能解决方案的发展与部署。此外,还探讨了关键挑战,并强调了八个未来的研究方向。通过提供全面的观点,本文旨在推动AI的战略实施,促进下一代工程AI解决方案的发展。

1 介绍

在大数据时代,人工智能(AI)和机器学习(ML)解决方案越来越多地被应用于各个工程领域,如制造[16, 48]、预测性维护[11, 53]、能源[65, 17]、交通[59, 67]、医疗保健[69, 50]、设计[61, 68]、计算机视觉(CV)[12, 22]、自然语言处理(NLP)[41, 25]、建筑[63, 6]、机器人和自动化[46, 52]、农业[49, 8]、材料科学[7, 14]等。人工智能和机器学习在工程领域的应用预计会彻底改变传统做法,加速更智能、更高效、更环保的解决方案[23, 45, 31]。然而,工程问题的复杂性和多样性要

求开发定制的人工智能解决方案来应对特定挑战。认识到这一差距,工程人工智能已经作为一个系统学科出现,弥合了人工智能、机器学习和工程需求之间的鸿沟。本文确定了工程人工智能(“ABCDE”)中的关键要素。除了这些要素之外,还提出了一个由八个基本层次组成的结构化生态系统框架,以指导从业人员和研究人员开发强大且高效的工程人工智能生态系统。此外,还讨论了关键挑战和未来的研究方向。通过这一探索,这篇观点论文旨在为不同工程领域的人工智能应用提供战略指导,促进工程中的人工智能创新和实际应用。

2 工程AI的关键要素:ABCDE

工程AI的基础组成部分可以归类为“ABCDE”,如图1所示,其中前三个组件——算法、大数据和计算能力——构成了AI技术的关键要素。(A. 算法)代表先进的AI和ML方法,(B. 大数据)涉及工程特定数据的收集、存储和处理,而(C. 计算)指的是最先进的计算基础设施,包括高性能芯片和云资源。这些元素共同构建了工程中以AI驱动的任务的基础。除了这“ABC”组件外,“DE”对扩展为三个关键路径:(AI+)基础设施,($\times$ AI)平台,和(+AI)产品。1) (AI+)基础设施路径强调物理和能源系统,(D.1 数据中心)支持人工智能计算和数据存储,并且(E.1 电力)为AI基础设施供电。2) ($\times$ AI)平台路径专注于工业领域的知识(D.2 域)和由AI驱动的生态系统(E.2 生态系统)的发展,以创建针对不同工程领域的人工智能解决方案。3) (+AI)产品路径将由AI支持的设备(D.3 设备)与边缘计算环境(E.3 边缘)相连接,使数据源附近能够

*Corresponding author




图 1. 工程 AI 的关键要素：ABCDE。

进行实时处理和决策制定。虽然 ABC 组件构成了开发人工智能系统所需的核心技术基础，但它们之间存在动态影响关系。算法的进步需要更大的计算能力和更多样化的数据，而计算创新以及大量的特定领域数据推动了新算法的发展。DE 组件定义了由 ABC 组件启用的人工智能技术的部署和使用方式及地点。这些路径界定了工程化人工智能的实际应用环境，每条路径发挥着不同的作用：提供计算和能源支持（数据中心、电力）、整合领域知识和生态系统（领域、生态），以及在边缘部署智能嵌入式应用（设备、边缘）。

3 工程人工智能生态的概念框架

图 2 展示了提出的工程人工智能生态系统，该系统作为设计、部署和优化不同工程领域中人工智能解决方案的全面指南。此框架为从业人员提供了制定工程人工智能系统开发与实施策略的系统方法。它包含八个基本层次：“问题识别层”，“AI 基础设施层”，“AI 模型开发层”，“数据基础层”，“知识整合层”，“可解释性与可信度层”，“评估与反馈层”，以及“部署与集成层”。这些层次共同确保未来的工程人工智能系统是自主的、协作的、可解释的、有韧性的，并且具有可扩展性（**关键属性**），最终实现零事故、零停机、零浪费、零污染和零缺陷（**工程目标**）。每个层次的具体说明如下。

3.1 问题识别层

问题识别层是工程 AI 生态系统中的第一步。这一层专注于定义 AI 系统旨在解决的具体工程问题。它包

括：(1) 理解问题的目的和范围；(2) 识别技术限制、痛点、潜在挑战和期望的结果；(3) 合作并进行详细分析以获得见解。最终，从业者将有信心通过后续层次使用 AI 和 ML 技术来解决问题。

3.2 人工智能基础设施层

人工智能基础设施层作为概念框架的骨干，提供了支持人工智能开发和部署所需的硬件、软件和网络资源。在硬件方面，这包括计算资源如 CPU、GPU、TPU、云计算服务、服务器和物联网设备。还涉及存储解决方案，包括高速存储、分布式文件系统和数据库，以实现高效的数据存储和管理。在软件方面，基础设施支持各种人工智能框架（例如 TensorFlow、PyTorch）、库（例如 Scikit-learn）以及开发工具（例如 Jupyter、Google Colab），以促进数据处理和模型开发。此外，网络资源确保组件之间的有效通信并实现系统间无缝的数据交换。从业者应根据其具体问题需求选择合适的平台和资源，以优化成本、时间和效率。

3.3 数据基础层

数据基础层，作为“AI 模型开发层”的必要前提，涉及整个数据收集、存储、管理和分析的过程，从而生成适用于 AI 应用的高质量数据集 [62, 35]。在由“AI 基础设施层”支持的数据采集之后，这一层执行诸如清理、处理缺失值、标准化和其他必要的转换等预处理任务，同时确保数据质量及其对于后续阶段的充足性。如需进一步增强其对工程问题的应用性，则会对数据进




图 2. 工程人工智能生态系统概念框架。

行特定领域的标注。最终，该层旨在生成适合下游流程使用的有用且可用的数据，从而实现高效准确的 AI 模型开发。

3.4 知识整合层

这一层确保领域专长被整合到 AI 模型和工作流程中。这需要系统地探索和发展知识的存储、检索、共享及应用 [24]。通过将工程原理、规则以及特定领域的知识嵌入到 AI 模型开发中，这一层增强了对复杂工程问题的理解，并最大限度地减少了潜在疏忽，从而提高了模型的准确性、可靠性与与现实世界工程场景的相关性。代表性技术包括基于本体的建模、基于规则的推理系统、知识图谱构建以及使用大型语言模型进行信息

检索和摘要。

3.5 可解释性与可信度层

在开发 AI 模型时，可解释性和可信度与高模型性能一样，在工程领域中至关重要。深度神经网络的黑箱性质常常引发对模型如何做出预测、为何作出某些决定以及这些结果可靠性的担忧。为了解决这些问题，这一层重点关注两个关键领域：发展可解释的人工智能 (XAI) 技术，如局部可解释的模型不可知论解释 (LIME) [47]，和 SHapley 加性解释值 (SHAP) [40]，以澄清模型决策过程及其背后的推理 [3, 2]，以及利用不确定性量化或概率机器学习方法来处理预测中的不确定性并增强模型的可靠性 [1, 43]。

3.6 人工智能模型开发层

这一层是生态系统框架的核心，由“数据基础层”、“知识整合层”和“可解释性和可信度层”支持，专注于为特定工程任务设计、训练和验证 AI 模型。这涉及：(1) 选择合适的 AI 和 ML 技术；(2) 开发和优化新的算法或架构；(3) 使用工程基准或实际数据训练和验证模型；以及 (4) 管理 AI 模型的生命周期，包括部署、监控、更新和重新训练 [4]。可以在工程领域应用广泛的机器学习算法，包括传统的机器学习算法，如基于树的方法、聚类方法和支持向量机，以及深度学习架构，包括卷积神经网络 (CNNs) [21, 37]、循环神经网络 (RNNs) [66]、转换器 [58, 39] 及其变体，这些算法使用 PyTorch 和 TensorFlow 等平台实现。

3.7 评估与反馈层

在将 AI 解决方案应用于现有工程系统之前，“评估与反馈层”作为“AI 模型开发层”的补充，专注于对 AI 解决方案的持续评估和优化 [19, 30]。这包括使用标准性能指标来评估模型以识别改进领域，并根据需要为特定问题开发专门的指标以提高模型准确性。此外，还收集用户和领域专家的反馈意见进一步完善 AI 模型。

3.8 部署与集成层

最后一层是在现有的工程系统中部署 AI 解决方案，确保与当前工作流程和技术无缝集成。它还涉及监控部署后的 AI 模型性能，以及及时调整和优化模型以提高模型性能和运营效率。[10, 56] 提出的概念框架可以应用于多种工程领域，包括制造、能源、交通、医疗保健、设计、计算机视觉、自然语言处理、建筑、机器人技术、采矿、农业、材料科学和生物工程。

总体而言，这些层次是相互关联的而不是严格按顺序排列的。该过程始于问题识别，并得到 AI 基础设施层提供的基础支持。框架的核心是 AI 模型开发层，它直接由数据基础、知识整合和可解释性与可信度层启用。这些支撑层通过高质量的数据、领域专长和解释机制丰富了建模过程。在模型开发之后，评估与反馈层通过监控性能并结合用户和实际部署结果的反馈来促进迭代改进。最后，部署与集成层确保经过验证的 AI

模型被嵌入到现实世界的工程系统中。

4 工程人工智能的挑战

图 3 总结了传统机器学习方法和在工程领域常用的各种算法。这些方法已在不同领域广泛采用以解决不同的工程挑战。此外，随着深度学习的进步，基于神经网络的方法越来越多地应用于各种工程应用中。诸如卷积神经网络 CNNs [21, 37]、循环神经网络 RNNs [66]、变换器 transformers [58, 39] 及其变体在处理大量数据时通常表现出更好的性能。然而，尽管有这些进展，人工智能在工程中的实施仍面临一些挑战，如下所述：

数据质量人工智能模型的有效性高度依赖于数据的质量。工程数据通常会遇到诸如缺失值、噪声、不一致性、类别不平衡或缺乏标签等问题。这些挑战需要强大的预处理和验证程序，以确保数据是有用且可用的。

多模态数据整合一些工程问题需要整合来自多种模态的数据，如传感器读数、参数数据、图像或文本数据。传统机器学习方法往往难以整合和处理这些异构数据类型。

领域转移在某些工程应用中，数据分布可能会由于环境条件、操作设置或其他因素的变化而发生变化。在一个特定数据集上训练的人工智能模型可能难以在面对新数据或不断变化的数据分布时保持准确性和可靠性。

模型可解释性确保 AI 模型的可解释性仍然是工程领域的一大挑战，因为复杂的模型如神经网络通常被认为是“黑箱”，这使得理解与解释 AI 模型如何进行预测或决策变得困难。

模型泛化传统的机器学习模型常常过度拟合特定的数据集，这限制了它们在新数据上的表现能力。在工程 AI 中，实现跨多种场景和未见条件下的鲁棒模型性能是至关重要的，需要开发能够可靠泛化和适应的模型。

5 未来方向

图 4 提供了工程人工智能未来发展方向的概述。这一视角有助于更好地理解关键方法和进展，并识别未来研究的关键领域。八个关键的研究方向如下所述：

Traditional Machine Learning Methods and Algorithms Used in Engineering								
Supervised Learning	Regression (Prediction)	Linear Regression	Polynomial Regression	Ridge & Lasso Regression	Kalman Filters/ Particle Filters	Bayesian Regression	Support Vector Regression	
	Classification	K-Nearest Neighbors	Support Vector Machine		Logistic Regression	Random Forest	Naïve Bayes	
		Hidden Markov Models	Gaussian Discriminant Analysis		Decision Trees	Self-Organizing Map		
Unsupervised Learning	Clustering	K-Means Clustering	Hierarchical Clustering	DBSCAN	Latent Dirichlet Allocation		Gaussian Mixture Models	
	Dimensionality Reduction	Principle Component Analysis	Singular Value Decomposition	Linear Discriminant Analysis	Factor Analysis	t-SNE	Independent Component Analysis	
	Prediction	Kalman Filters	Particle Filters	Similarity-Based		Markov Chains	Hidden Markov Models	
Others	Anomaly Detection	One-Class Support Vector Machine	Statistical Process Control		SOM-MQE	Isolation Forest	Thresholding Models	
	Reinforcement Learning	Value-Based (Q-Learning)	Value-Based (SARSA) (State-Action-Reward-State-Action)	Policy-Based (REINFORCE)	Policy-Based (Proximal Policy Optimization)		Actor-Critic	Model-Based RL
	Optimization	Gradient Descent	Genetic Algorithms	Particle Swarm Optimization	Grid Search	Bayesian Optimization	Convex Optimization	
PS: (Deep) Neural network-based models such as CNNs, RNNs, transformers, and their variants can be applied in most of situations listed above and demonstrate even greater performance when dealing with large amounts of data. As a result, we categorized them as advanced machine learning methods.								

图 3. 基础机器学习方法和算法在工程中的应用。

迁移学习与领域适应：使在一个领域训练的模型能够有效地应用于另一个领域，当目标领域的数据稀缺或收集成本高昂时 [18, 34, 15]。未来的研究可以集中在完善这些技术，以更好地处理跨域应用、目标领域的有限标注数据和动态工业环境。

质量流 & X 流：该范式旨在为多阶段制造过程中的工程系统提供连续监测和优化 [28, 29]。未来的发展可以将实时分析与预测能力集成，以实现工业系统中的动态质量控制、预测性维护和自适应过程管理。

基于相似性的机器学习利用相似度测量来识别数据中的模式、关系和聚类，以提高预测准确性 [32, 64, 44]。未来的工作可以探索处理高维数据集的方法，改进聚类技术，并整合可解释性特征以在工程系统中建立信任和可靠性。

基于数字孪生的机器学习通过将数字孪生（结合物理和虚拟系统）与机器学习集成，这种方法能够实现实时数据分析、仿真和预测 [27, 55, 26]。未来的发展可以集中在开发基于新型数字孪生的机器学习，以实现

实时监控、优化系统性能，并通过动态和准确的系统表示来做出更好的决策。

多模态机器学习旨在结合来自多种模态的信息，如图像、文本、音频、表格数据或传感器信号，以创建更强大和全面的模型 [38, 54, 51]。未来的研究可以探索跨模态学习效率、更好的表示学习方法、高效的信息对齐技术等。

基于物理和数据驱动的混合模型结合基于物理的建模和数据驱动方法的优势，以提高复杂系统中的预测准确性、泛化能力和可解释性 [60, 33]。未来的研究方向包括开发知识驱动的机器学习算法、代理模型以及自动设计和优化混合模型。

大型语言模型 (LLM) & 工业大型知识模型 (ILKM) 大型语言模型在自然语言处理方面展现了卓越的能力，显示出人工通用智能 (AGI) 的潜力 [71, 13]。对于未来工程 AI 的发展，通过整合结构化和非结构化数据、知识库以及特定领域的大型语言模型，开发领域特定的 ILKMs 有着令人期待的机会 [30]。这些模型可




图 4. 未来工程人工智能研究的方向。每个子图均来自其相应的来源：(1) 迁移学习与领域自适应 [34]; (2) 质量流与 X 流 [28]; (3) 基于相似性的机器学习 [32]; (4) 基于数字孪生的机器学习 [26]; (5) 多模态机器学习 [38]; (6) 混合物理基础与数据驱动模型 [33]; (7) 大型语言模型与工业大型知识模型 [30]; (8) 基础模型 [9]。

表 1. 工程 AI 未来研究方向的定性路线图。

研究方向	可行性	影响	领先部门
Transfer learning & domain adaptation	High	Moderate	Academia + Industry
Similarity-based machine learning	High	Moderate	Academia + Industry
Digital twin-based machine learning	Moderate	High	Academia + Industry
Stream-of-X	Moderate	High	Academia + Industry
基于物理和 数据驱动的混合模型	Low	High	Academia
Multi-modal machine learning	Low	High	Academia
LLM and ILKM	Low	High	Academia + Industry
Foundation models for engineering AI	Very Low	Transformative	Academia + Government

以解决复杂的工程挑战，并促进智能的数据驱动决策。

基础模型是一个大规模的机器学习模型，在大量数据集上进行了预训练，可以通过最小的额外训练进行微调或适应特定的下游任务 [9]。未来在于开发不同工程领域中的特定工程基础模型，如故障预测与健康管理 (PHM) [36]、时间序列 [20]、CV [5]、NLP [57]、医疗保健 [42]、制造 [70] 等。

为了支持战略规划，表 1 提出了未来研究方向的结构化路线图，涵盖三个维度：(1) 可行性，表明技术的成熟度和准备情况；(2) 影响力，反映对推进工程人工智能的预期影响；以及 (3) 领导领域，包括行业、学术界或政府。这些评估基于专家判断和当前文献及实践的趋势。最后，该表作为重要参考，帮助研究人员和业界从业者评估成熟度、战略价值、投资优先级和协作责任。

6 结论

随着 AI 和 ML 不断重新定义技术边界，迫切需要在各个工程领域系统地开发 AI 解决方案以最大化其影响。本文确定了工程 AI 的基础“ABCDE”元素，提出了一个全面的工程 AI 生态系统概念框架，讨论了关键挑战，并强调了未来方向。总之，本研究为实践者提供

了一个统一且结构化的途径，在多样化的工程领域内有效实施 AI 解决方案。

参考文献

- [1] M. Abdar, F. Pourpanah, S. Hussain, D. Reza-zadegan, L. Liu, M. Ghavamzadeh, P. Fieguth, X. Cao, A. Khosravi, U. R. Acharya, et al. A review of uncertainty quantification in deep learning: Techniques, applications and challenges. *Information fusion*, 76:243–297, 2021.
- [2] S. Ali, T. Abuhmed, S. El-Sappagh, K. Muhammad, J. M. Alonso-Moral, R. Confalonieri, R. Guidotti, J. Del Ser, N. Díaz-Rodríguez, and F. Herrera. Explainable artificial intelligence (xai): What we know and what is left to attain trustworthy artificial intelligence. *Information fusion*, 99:101805, 2023.
- [3] A. B. Arrieta, N. Díaz-Rodríguez, J. Del Ser, A. Bennetot, S. Tabik, A. Barbado, S. García, S. Gil-López, D. Molina, R. Benjamins, et al. Explainable artificial intelligence (xai): Concepts,

- taxonomies, opportunities and challenges toward responsible ai. *Information fusion*, 58:82–115, 2020.
- [4] R. Ashmore, R. Calinescu, and C. Paterson. As-suring the machine learning lifecycle: Desiderata, methods, and challenges. *ACM Computing Surveys (CSUR)*, 54(5):1–39, 2021.
- [5] M. Awais, M. Naseer, S. Khan, R. M. Anwer, H. Cholakkal, M. Shah, M.-H. Yang, and F. S. Khan. Foundation models defining a new era in vision: a survey and outlook. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025.
- [6] S. K. Baduge, S. Thilakarathna, J. S. Perera, M. Arashpour, P. Sharafi, B. Teodosio, A. Shringi, and P. Mendis. Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. *Automation in Construction*, 141:104440, 2022.
- [7] R. Batra, L. Song, and R. Ramprasad. Emerging materials intelligence ecosystems propelled by machine learning. *Nature Reviews Materials*, 6(8):655–678, 2021.
- [8] L. Benos, A. C. Tagarakis, G. Dolias, R. Berruto, D. Kateris, and D. Bochtis. Machine learning in agriculture: A comprehensive updated review. *Sensors*, 21(11):3758, 2021.
- [9] R. Bommasani, D. A. Hudson, E. Adeli, R. Altman, S. Arora, S. von Arx, M. S. Bernstein, J. Bohg, A. Bosselut, E. Brunskill, et al. On the opportunities and risks of foundation models. *arXiv preprint arXiv:2108.07258*, 2021.
- [10] J. Bosch, H. H. Olsson, and I. Crnkovic. Engineering ai systems: A research agenda. *Artificial intelligence paradigms for smart cyber-physical systems*, pages 1–19, 2021.
- [11] T. P. Carvalho, F. A. Soares, R. Vita, R. d. P. Francisco, J. P. Basto, and S. G. Alcalá. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137:106024, 2019.
- [12] J. Chai, H. Zeng, A. Li, and E. W. Ngai. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6:100134, 2021.
- [13] Y. Chang, X. Wang, J. Wang, Y. Wu, L. Yang, K. Zhu, H. Chen, X. Yi, C. Wang, Y. Wang, et al. A survey on evaluation of large language models. *ACM Transactions on Intelligent Systems and Technology*, 15(3):1–45, 2024.
- [14] A. K. Cheetham and R. Seshadri. Artificial intelligence driving materials discovery? perspective on the article: Scaling deep learning for materials discovery. *Chemistry of Materials*, 36(8):3490–3495, 2024.
- [15] Y. Ding, M. Jia, J. Zhuang, Y. Cao, X. Zhao, and C.-G. Lee. Deep imbalanced domain adaptation for transfer learning fault diagnosis of bearings under multiple working conditions. *Reliability Engineering & System Safety*, 230:108890, 2023.
- [16] A. Dogan and D. Birant. Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166:114060, 2021.
- [17] A. Entezari, A. Aslani, R. Zahedi, and Y. Noorollahi. Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45:101017, 2023.
- [18] A. Farahani, S. Voghoei, K. Rasheed, and H. R. Arabnia. A brief review of domain adaptation. *Advances in data science and information engineering: proceedings from ICDATA 2020 and IKE 2020*, pages 877–894, 2021.
- [19] L. Freeman. Test and evaluation for artificial intelligence. *Insight*, 23(1):27–30, 2020.

- [20] M. Goswami, K. Szafer, A. Choudhry, Y. Cai, S. Li, and A. Dubrawski. Moment: A family of open time-series foundation models. *arXiv preprint arXiv:2402.03885*, 2024.
- [21] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai, et al. Recent advances in convolutional neural networks. *Pattern recognition*, 77:354–377, 2018.
- [22] M.-H. Guo, T.-X. Xu, J.-J. Liu, Z.-N. Liu, P.-T. Jiang, T.-J. Mu, S.-H. Zhang, R. R. Martin, M.-M. Cheng, and S.-M. Hu. Attention mechanisms in computer vision: A survey. *Computational visual media*, 8(3):331–368, 2022.
- [23] Z. Jan, F. Ahamed, W. Mayer, N. Patel, G. Grossmann, M. Stumptner, and A. Kuusk. Artificial intelligence for industry 4.0: Systematic review of applications, challenges, and opportunities. *Expert Systems with Applications*, 216:119456, 2023.
- [24] M. H. Jarrahi, D. Askay, A. Eshraghi, and P. Smith. Artificial intelligence and knowledge management: A partnership between human and ai. *Business Horizons*, 66(1):87–99, 2023.
- [25] D. Khurana, A. Koli, K. Khatter, and S. Singh. Natural language processing: state of the art, current trends and challenges. *Multimedia tools and applications*, 82(3):3713–3744, 2023.
- [26] J. Lee, M. Azamfar, J. Singh, and S. Siahpour. Integration of digital twin and deep learning in cyber-physical systems: towards smart manufacturing. *IET Collaborative Intelligent Manufacturing*, 2(1):34–36, 2020.
- [27] J. Lee, B. Bagheri, and H.-A. Kao. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing letters*, 3:18–23, 2015.
- [28] J. Lee, P. Gore, X. Jia, S. Siahpour, P. Kundu, and K. Sun. Stream-of-quality methodology for industrial internet-based manufacturing system. *Manufacturing Letters*, 34:58–61, 2022.
- [29] J. Lee, D.-Y. Ji, and Y.-M. Hsu. Novel topological machine learning methodology for stream-of-quality modeling in smart manufacturing. *Manufacturing Letters*, 2025.
- [30] J. Lee and H. Su. A unified industrial large knowledge model framework in industry 4.0 and smart manufacturing. *International Journal of AI for Materials and Design*, 1(2):41–47, 2024.
- [31] J. Lee and H. Su. Rethinking industrial artificial intelligence: A unified foundation framework. *International Journal of AI for Materials and Design*, page 025080006, 2025.
- [32] D. Lemm, G. F. von Rudorff, and O. A. von Lilienfeld. Improved decision making with similarity based machine learning: Applications in chemistry. *Machine Learning: Science and Technology*, 4(4):045043, 2023.
- [33] H. Li, Z. Zhang, T. Li, and X. Si. A review on physics-informed data-driven remaining useful life prediction: Challenges and opportunities. *Mechanical Systems and Signal Processing*, 209:111120, 2024.
- [34] W. Li, R. Huang, J. Li, Y. Liao, Z. Chen, G. He, R. Yan, and K. Gryllias. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges. *Mechanical Systems and Signal Processing*, 167:108487, 2022.
- [35] X. Li, C. Yang, C. Møller, and J. Lee. Data issues in industrial ai system: A meta-review and research strategy. *arXiv preprint arXiv:2406.15784*, 2024.
- [36] Y.-F. Li, H. Wang, and M. Sun. Chatgpt-like large-scale foundation models for prognostics and

- health management: A survey and roadmaps. *Reliability Engineering & System Safety*, 243:109850, 2024.
- [37] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12):6999–7019, 2021.
- [38] P. P. Liang, A. Zadeh, and L.-P. Morency. Foundations & trends in multimodal machine learning: Principles, challenges, and open questions. *ACM Computing Surveys*, 56(10):1–42, 2024.
- [39] T. Lin, Y. Wang, X. Liu, and X. Qiu. A survey of transformers. *AI open*, 3:111–132, 2022.
- [40] S. M. Lundberg and S.-I. Lee. A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30, 2017.
- [41] B. Min, H. Ross, E. Sulem, A. P. B. Veyseh, T. H. Nguyen, O. Sainz, E. Agirre, I. Heintz, and D. Roth. Recent advances in natural language processing via large pre-trained language models: A survey. *ACM Computing Surveys*, 56(2):1–40, 2023.
- [42] M. Moor, O. Banerjee, Z. S. H. Abad, H. M. Krumholz, J. Leskovec, E. J. Topol, and P. Rajpurkar. Foundation models for generalist medical artificial intelligence. *Nature*, 616(7956):259–265, 2023.
- [43] K. P. Murphy. *Probabilistic machine learning: an introduction*. MIT press, 2022.
- [44] C. Niu, M. Li, F. Fan, W. Wu, X. Guo, Q. Lyu, and G. Wang. Noise suppression with similarity-based self-supervised deep learning. *IEEE transactions on medical imaging*, 42(6):1590–1602, 2022.
- [45] I. K. Nti, A. F. Adekoya, B. A. Weyori, and O. Nyarko-Boateng. Applications of artificial intelligence in engineering and manufacturing: a systematic review. *Journal of Intelligent Manufacturing*, 33(6):1581–1601, 2022.
- [46] J. Ribeiro, R. Lima, T. Eckhardt, and S. Paiva. Robotic process automation and artificial intelligence in industry 4.0—a literature review. *Procedia Computer Science*, 181:51–58, 2021.
- [47] M. T. Ribeiro, S. Singh, and C. Guestrin. “why should i trust you?” explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pages 1135–1144, 2016.
- [48] S. Sahoo and C.-Y. Lo. Smart manufacturing powered by recent technological advancements: A review. *Journal of Manufacturing Systems*, 64:236–250, 2022.
- [49] A. Sharma, A. Jain, P. Gupta, and V. Chowdary. Machine learning applications for precision agriculture: A comprehensive review. *IEEE Access*, 9:4843–4873, 2020.
- [50] K. Singhal, S. Azizi, T. Tu, S. S. Mahdavi, J. Wei, H. W. Chung, N. Scales, A. Tanwani, H. Cole-Lewis, S. Pfohl, et al. Large language models encode clinical knowledge. *Nature*, 620(7972):172–180, 2023.
- [51] B. Song, R. Zhou, and F. Ahmed. Multi-modal machine learning in engineering design: A review and future directions. *Journal of Computing and Information Science in Engineering*, 24(1):010801, 2024.
- [52] M. Soori, B. Arezoo, and R. Dastres. Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 3:54–70, 2023.
- [53] H. Su and J. Lee. Machine learning approaches for diagnostics and prognostics of industrial systems using open source data from phm data challenges:

- A review. *International Journal of Prognostics and Health Management*, 15(2), 2024.
- [54] H. Su, B. Song, and F. Ahmed. Multi-modal machine learning for vehicle rating predictions using image, text, and parametric data. In *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, volume 87295, page V002T02A089. American Society of Mechanical Engineers, 2023.
 - [55] F. Tao, H. Zhang, A. Liu, and A. Y. Nee. Digital twin in industry: State-of-the-art. *IEEE Transactions on industrial informatics*, 15(4):2405–2415, 2018.
 - [56] S. Tatineni and A. Katari. Advanced ai-driven techniques for integrating devops and mlops: Enhancing continuous integration, deployment, and monitoring in machine learning projects. *Journal of Science & Technology*, 2(2):68–98, 2021.
 - [57] H. Touvron, T. Lavril, G. Izacard, X. Martinet, M.-A. Lachaux, T. Lacroix, B. Rozière, N. Goyal, E. Hambro, F. Azhar, et al. Llama: Open and efficient foundation language models. *arXiv preprint arXiv:2302.13971*, 2023.
 - [58] A. Vaswani. Attention is all you need. *Advances in Neural Information Processing Systems*, 2017.
 - [59] M. Veres and M. Moussa. Deep learning for intelligent transportation systems: A survey of emerging trends. *IEEE Transactions on Intelligent transportation systems*, 21(8):3152–3168, 2019.
 - [60] J. Wang, Y. Li, R. X. Gao, and F. Zhang. Hybrid physics-based and data-driven models for smart manufacturing: Modelling, simulation, and explainability. *Journal of Manufacturing Systems*, 63:381–391, 2022.
 - [61] X. Wang, A. Liu, and S. Kara. Machine learning for engineering design toward smart customization: A systematic review. *Journal of Manufacturing Systems*, 65:391–405, 2022.
 - [62] S. E. Whang, Y. Roh, H. Song, and J.-G. Lee. Data collection and quality challenges in deep learning: A data-centric ai perspective. *The VLDB Journal*, 32(4):791–813, 2023.
 - [63] S. Xu, J. Wang, W. Shou, T. Ngo, A.-M. Sadick, and X. Wang. Computer vision techniques in construction: a critical review. *Archives of Computational Methods in Engineering*, 28:3383–3397, 2021.
 - [64] B. Xue, H. Xu, X. Huang, K. Zhu, Z. Xu, and H. Pei. Similarity-based prediction method for machinery remaining useful life: A review. *The International Journal of Advanced Manufacturing Technology*, 121(3):1501–1531, 2022.
 - [65] Z. Yao, Y. Lum, A. Johnston, L. M. Mejia-Mendoza, X. Zhou, Y. Wen, A. Aspuru-Guzik, E. H. Sargent, and Z. W. Seh. Machine learning for a sustainable energy future. *Nature Reviews Materials*, 8(3):202–215, 2023.
 - [66] Y. Yu, X. Si, C. Hu, and J. Zhang. A review of recurrent neural networks: Lstm cells and network architectures. *Neural computation*, 31(7):1235–1270, 2019.
 - [67] T. Yuan, W. da Rocha Neto, C. E. Rothenberg, K. Obraczka, C. Barakat, and T. Turetti. Machine learning for next-generation intelligent transportation systems: A survey. *Transactions on emerging telecommunications technologies*, 33(4):e4427, 2022.
 - [68] N. Yüksel, H. R. Börklü, H. K. Sezer, and O. E. Canyurt. Review of artificial intelligence applications in engineering design perspective. *Engineering Applications of Artificial Intelligence*, 118:105697, 2023.
 - [69] A. Zhang, L. Xing, J. Zou, and J. C. Wu. Shifting machine learning for healthcare from development to deployment and from models to data. *Nature Biomedical Engineering*, 6(12):1330–1345, 2022.

- [70] H. Zhang, S. D. Semujju, Z. Wang, X. Lv, K. Xu, L. Wu, Y. Jia, J. Wu, W. Liang, R. Zhuang, et al. Large scale foundation models for intelligent manufacturing applications: a survey. *Journal of Intelligent Manufacturing*, pages 1–52, 2025.
- [71] W. X. Zhao, K. Zhou, J. Li, T. Tang, X. Wang, Y. Hou, Y. Min, B. Zhang, J. Zhang, Z. Dong, et al. A survey of large language models. *arXiv preprint arXiv:2303.18223*, 2023.