

שילוב יישומי בינה מלאכותית בהנדסה ובהנדסת מערכות

סקר ספרות

אליעזר שיין
חיים שורץ
אביגדור זוננשיין

מוסד שמואל נאמן
למחקר מדיניות לאומית



חינוך מהנדסים | 03/26





שילוב יישומי בינה מלאכותית בהנדסה ובהנדסת מערכות

סקר ספרות

אליעזר שיין

חיים שורץ

אביגדור זוננשיין

תוכן עניינים

1.	רקע והקדמה	5.....
2.	מתודולוגיה	20
3.	תקציר	21
3.1	סיכום התובנות המרכזיות בכל אחד מתחומי ההנדסה הנובעות מסקר הספרות	22
3.2	השפעת הבינה המלאכותית (AI) על הנדסת מכונות, הנדסת אווירונאוטיקה, והנדסת חשמל/אלקטרוניקה.	24
3.3	נושאים חוצי-תחומים	26
4.	סקירה כללית - שיטות וטכניקות של בינה מלאכותית	27
4.1	סקירה כללית של בינה מלאכותית	27
4.2	שיטות וטכניקות של בינה מלאכותית	28
4.3	בינה מלאכותית כללית - General AI	33
5.	בינה מלאכותית בהנדסת מערכות	36
6.	טכניקות של בינה מלאכותית בהנדסה	42
6.1	מיפוי שיטות מבוססות בינה מלאכותית לשלבי תכן הנדסי	42
6.2	השפעות הבינה המלאכותית על תחום ההנדסה	53
7.	השפעת הבינה המלאכותית על תהליכי תכן הנדסי עבור מערכות דינמיות	55
8.	השפעת בינה מלאכותית על תהליכי תכן בתוכנה	62
8.1	המעבר מהנדסה מבוססת כללים לפיתוח מונחה נתונים	63
8.2	כיצד פיתוח תוכנה משתנה – ואיך הוא משפיע על הכישורים הנדרשים	65
8.3	מגמות עתידיות	67
9.	השפעת הבינה המלאכותית על תחום הנדסת האלקטרוניקה	69
10.	השפעת הבינה המלאכותית על תחום הנדסת אווירונאוטיקה	72

11. בינה מלאכותית בתחומי הנדסה חוצי דיסציפלינות	75
11.1 השפעת בינה מלאכותית על נושא הסימולציה בהנדסה	75
11.2 השפעת בינה מלאכותית על הנדסת גורמי אנוש	80
11.3 השפעת בינה מלאכותית על הנדסת איכות	81
11.4 מחזור החיים של מוצר חדש כולל הנדסת ייצור, תכן להרכבה, הנדסת תחזוקתיות, עיצוב/תכן לעלות, שיווק ומכירה	84
11.5 כיצד בינה מלאכותית משנה את עולם הייצור בתחום של Additive Mfg.	86
11.6 שילוב בתוכניות לימודים ותפקיד הבינה המלאכותית	89
11.7 יישומי בינה מלאכותית בהנדסת יצור	90
11.8 הנדסה בת קיימא: בינה מלאכותית לעיצוב ידידותי לסביבה	91
12. סיכום - מהפכת החדשנות הבאה בהנדסה - מונעת על ידי בינה מלאכותית	94
13. רשימת מקורות	95

1. רקע והקדמה

בנוף הטכנולוגי המתפתח במהירות, בינה מלאכותית (AI) צצה ככוח טרנספורמטיבי בעל פוטנציאל לחולל מהפכה כמעט בכל תחום, כולל בהנדסה והנדסת מערכות.

לבינה מלאכותית יש את היכולת לשפר את קבלת ההחלטות, לייעל מערכות מורכבות ולהפוך לאוטומטיים תהליכים שגרתיים בתחומי הנדסה שונים. בין אם בהנדסה אזרחית, הנדסת מכונות, הנדסת חשמל ואלקטרוניקה, הנדסת תוכנה או חלל, בינה מלאכותית יכולה להפחית משמעותית את זמן התכן, לשפר את איכות המוצר ולחזות התנהגויות מערכת בתנאים שונים. בהנדסת מערכות - תחום בין-תחומי המתמקד בתכן, אינטגרציה וניהול של מערכות מורכבות - בינה מלאכותית מציעה מתודולוגיות חדשות לניהול מורכבות המערכת, הסתגלות לסביבות דינמיות ושיפור החוסן הכולל של המערכת.

יתר על כן, גישות המונעות על ידי בינה מלאכותית כמו למידת מכונה, למידה עמוקה ועיבוד שפה טבעית יכולות לחולל מהפכה באופן שבו מהנדסים מטפלים בנתונים. בתחומי הנדסה רבים, נוצרות כמויות גדולות של נתונים באמצעות חיישנים, סימולציות וכלי ניטור. בינה מלאכותית מאפשרת ניתוח יעיל של נתונים אלה, חשיפת דפוסים נסתרים ויצירת תובנות מעשיות. בהנדסת מערכות, שבה התיאום של תת-מערכות מרובות הוא קריטי, בינה מלאכותית יכולה לתמוך באוטומציה של מידול מערכות, ניתוח דרישות והערכת סיכונים.

יש חשיבות להתמודדות עם האתגרים האתיים, המשפטיים והטכניים הקשורים לשילוב בינה מלאכותית והמהווים נושא חדש ומתפתח בתחום ניהול הסיכונים. יש ללמוד ולתעד בקפידה סוגיות כגון הטיה אלגוריתמית, שקיפות, אחריות ובטיחות. ולהציע מסגרות ותקנים לשימוש אחראי בבינה מלאכותית ביישומים הנדסיים (פרקטיקות הנדסיות), ובכך להנחות את פיתוחן של מערכות אמינות ובנות קיימא. בינה מלאכותית כבר ממלאת תפקיד משמעותי בחינוך ובפיתוח כוח אדם. ככל שבינה מלאכותית הופכת למרכיב מרכזי בפרקטיקה ההנדסית, קיים צורך גובר להגדיר מחדש תוכניות לימודים ותוכניות הכשרה.

סקר ספרות זה סוקר מספר רב של מאמרים אקדמיים על יישומי בינה מלאכותית בהנדסה והנדסת מערכות ותרומתם לקידום חדשנות טכנולוגית, שיפור יעילות המערכת והכנה לעתיד העבודה. הסקר כולל התייחסות למאמרים המקנים הבנה מעמיקה יותר של האופן שבו בינה מלאכותית יכולה לשנות תהליכים ומערכות הנדסיות, תוך התייחסות גם לממדים החברתיים והאתיים של טרנספורמציה זו.

נציין כי עקב ההתפתחות המהירה בתחום, כל סקר ספרות מתיישן במידה רבה ברגע שהוא נכתב. אנחנו נפעל להוציא עדכון עיתי הכולל פרסומים רלוונטיים מהעולם בכלל ומישראל בפרט.

להלן טבלת קיצורים והסברים של מושגים שונים בבינה מלאכותית בהנדסה ובהנדסת מערכת בפרט שבהם נעשה שימוש בסקר זה.

Table 1.1 Abbreviations and Terms used in articles and their meanings

Abbreviation or Term	Meaning and Explanation
Additive manufacturing (AM)	Additive manufacturing, also known as 3D printing, is a process that builds three-dimensional objects by adding material layer by layer from a digital design. This contrasts with subtractive manufacturing, which removes material from a block. Additive manufacturing enables the creation of complex geometries, customized parts, and can be more material-efficient than traditional methods.
Agentic AI	Agentic AI refers to AI systems that can autonomously make decisions and take actions to achieve specific goals, without constant human intervention. These systems exhibit agency, meaning they can act independently, reason, and adapt to changing circumstances to fulfill objectives.
AI	Artificial Intelligence (AI) Artificial intelligence (AI) is the development of computer systems that can perform tasks typically requiring human intelligence, such as learning, reasoning, and problem-solving. AI systems learn from vast amounts of data to recognize patterns, make decisions, and adapt to new information, enabling applications like virtual assistants, recommendation systems, and autonomous vehicles. A key subset of AI is machine learning, which allows computers to learn from data without explicit programming.
AI4SE vs. SE4AI	AI4SE (Artificial Intelligence for Systems Engineering) and SE4AI (Systems Engineering for Artificial Intelligence) represent a dual, complementary transformation in the engineering field. While both aim to improve system reliability, efficiency, and performance, they differ in their primary focus: AI4SE leverages AI to enhance engineering processes, while SE4AI applies engineering principles to create trustworthy AI.
AIoT	AIoT, or Artificial Intelligence of Things, is the convergence of Artificial Intelligence (AI) and the Internet of Things (IoT). It combines the data collection capabilities of IoT devices with the intelligence and analytical power of AI to create more efficient, automated, and insightful systems.

Abbreviation or Term	Meaning and Explanation
AR/VR	AR and VR, or Augmented Reality and Virtual Reality, are immersive technologies that blend digital and real-world experiences. AR overlays digital information onto the real world, while VR immerses users in a completely simulated environment. AR is often experienced through smartphones or smart glasses, while VR typically requires specialized headsets.
Artificial General Intelligence (AGI)	Artificial General Intelligence (AGI), also known as strong AI, is a hypothetical type of artificial intelligence that could possess the ability to understand, learn, and apply knowledge across a wide range of tasks at a level comparable to human intelligence. Unlike current narrow AI systems designed for specific tasks, AGI would be able to generalize knowledge and adapt to new situations like a human.
Artificial Intelligence (AI)	Artificial Intelligence (AI): The simulation of human intelligence processes by machines, including learning, reasoning, and self-correction.
BC	Blockchain (BC) is a decentralized, distributed, and immutable digital ledger that records transactions across a network of computers. By using cryptographic hashes, it creates a secure, chronological chain of data blocks, ensuring that records cannot be altered retroactively. This technology enables trustless, transparent, and secure data exchange without intermediaries.
BDA	Big Data Analysis (BDA), Big Data Analysis (BDA) is the process of examining massive, complex datasets (structured, semi-structured, unstructured) using advanced tools like machine learning and data mining to discover hidden patterns, trends, and correlations, enabling data-driven insights for better decision-making, risk management, product development, and operational efficiency. It tackles data characterized by the "5 Vs": Volume, Velocity, Variety, Veracity, and Value, going beyond traditional databases with distributed processing for rapid insights.

Abbreviation or Term	Meaning and Explanation
Computational Fluid Dynamics (CFD)	Computational fluid dynamics (CFD) is the science of using computers to predict liquid and gas flows based on the governing equations of conservation of mass, momentum, and energy. Fluids are all around us and sustain our lives in endless ways. The vibrations in your vocal cords generate pressure waves in the air that make speech possible, as well as hearing the spoken words. Without fluids, your tennis ball's topspin would be meaningless, and your airplane wouldn't generate any lift. Through CFD, we can analyze, understand, and predict the fluids that make up nearly every part of our world.
Computer-aided design (CAD)	Computer-Aided Design (CAD) is the use of computer software to create, modify, analyze, and optimize 2D drawings and 3D models for products, buildings, and other complex designs, replacing traditional manual drafting and enhancing precision, collaboration, and efficiency in development. It allows designers and engineers to visualize designs, simulate performance, create detailed documentation, and facilitate manufacturing, making it essential across industries like automotive, architecture, aerospace, and electronics. Computer-aided design (CAD) is a way to digitally create 2D drawings and 3D models of real-world products before they're ever manufactured. With 3D CAD, you can share, review, simulate, and modify designs easily, opening doors to innovative and differentiated products that get to market fast. https://www.ptc.com/en/technologies/cad
Computer-aided engineering (CAE)	Computer-Aided Engineering (CAE) refers to the use of computer software to analyze, simulate, and optimize the performance of engineered products and processes. It's a broad field encompassing various computational tools and techniques used throughout the product lifecycle, from design to manufacturing. CAE leverages simulation, validation, and optimization capabilities to enhance product development and improve efficiency.
Convolutional Neural Network (CNN)	In AI, CNN refers to a Convolutional Neural Network, a deep learning model primarily used for image recognition and processing, and other tasks involving data with a grid-like topology, such as video, audio, and time-series data. CNNs work by using "convolutional layers" with filters to automatically learn and extract key features (like edges or shapes) from raw data, efficiently processing it for tasks like object classification, facial recognition, and medical image analysis.

Abbreviation or Term	Meaning and Explanation
Cyber-physical systems (CPS)	Cyber-physical systems (CPS) are engineered systems that integrate computation, networking, and physical processes. They combine computational elements with physical processes, using sensors, actuators, and algorithms to monitor and control physical systems in real-time. This integration enables intelligent and responsive behavior, transforming how we interact with engineered systems.
Deep learning (DL)	Deep learning is a powerful type of machine learning that uses multilayered neural networks—inspired by the human brain—to learn complex patterns and make predictions from data. By training these "deep" networks with vast amounts of data, deep learning can automate sophisticated tasks such as image recognition, natural language processing (like in ChatGPT), and speech recognition, making it a core technology behind many modern artificial intelligence (AI) applications.
Design for Assembly (DFA)	Design for Assembly (DFA) is a design strategy that focuses on making products easy, fast, and inexpensive to assemble. It involves designing products with the assembly process in mind, aiming to minimize the number of parts, reduce assembly time and costs, and minimize material waste.
Design for maintenance (DFM)	Design for maintenance (DFM) is a product development approach focused on minimizing the effort, cost, and time required for maintaining a product throughout its lifecycle. It involves considering maintenance needs from the initial design phase, ensuring that products are designed to be easily and affordably maintained, repaired, or replaced. This approach leads to increased product lifespan, reduced downtime, and lower overall costs.
Design for Maintainability (DfM)	Design for Maintainability (DfM) is the practice of integrating maintenance needs into the initial design of a product or building to make future upkeep easier, safer, more cost-effective, and efficient, focusing on accessibility, appropriate materials, simple disassembly, and standardized components to reduce long-term operational costs and extend asset life. It's a key strategy to prevent premature deterioration, lower lifecycle costs, and improve a facility's sustainability and usability over time.

Abbreviation or Term	Meaning and Explanation
Design for Manufacturability (DFM)	AI is revolutionizing Design for Manufacturability (DFM) by enabling more efficient and cost-effective product development. AI algorithms can analyze vast datasets, optimize designs for various factors, and predict potential manufacturing issues early in the design process. This leads to reduced costs, faster production times, and improved product quality.
Design for Reliability (DfR)	Design for Reliability (DFR) is an engineering approach focused on proactively building reliability into a product or system during the design phase. It aims to prevent failures and ensure the product meets its intended reliability goals throughout its lifecycle. DFR involves using various tools and techniques to identify potential failure modes, assess risks, and implement design solutions to enhance robustness and longevity. Design for Reliability (DfR) is a proactive engineering process to build products that perform as specified under real-world conditions, integrating reliability at every lifecycle stage by identifying potential failures, modeling risks, and using tools like FMEA/FTA, HALT/HASS, and testing to ensure long-term function, reduce costs, and enhance customer satisfaction. It moves beyond reactive fixes to embed durability, using methods from early concept through manufacturing and disposal, considering materials, processes, and operating environments.
Design for Six Sigma (DfSS)	Design for Six Sigma (DFSS) is a methodology focused on creating new products, services, and processes with a focus on customer needs and achieving Six Sigma quality levels from the outset. It's a proactive approach that aims to prevent defects and optimize performance by embedding quality into the design phase, rather than trying to fix issues later in the process.
Design for Sustainability	Design for sustainability is an approach that prioritizes environmental and social well-being throughout the entire lifecycle of a product or system, aiming to minimize negative impacts and maximize positive contributions. It involves integrating sustainability principles into the design process, considering factors like material selection, energy efficiency, and end-of-life management. This approach is crucial for addressing global challenges like climate change and resource depletion, and it can lead to more durable, efficient, and socially responsible products and systems.

Abbreviation or Term	Meaning and Explanation
Design to Cost (DTC)	Design to Cost (DTC) is a management approach focused on integrating cost considerations into the product design and development process from the very beginning. It establishes cost as a key design constraint, aiming to achieve predetermined target costs while maintaining desired functionality and performance. This proactive approach helps to minimize costly redesigns later in the product lifecycle and improve overall cost-effectiveness.
DevOps	DevOps is a cultural philosophy, set of practices, and tools that merge software development (Dev) and IT operations (Ops) to automate and integrate processes, enabling faster, more reliable software delivery through collaboration, continuous integration/delivery (CI/CD), and feedback loops, breaking down traditional silos for increased speed, quality, and innovation. It focuses on a continuous cycle of planning, coding, building, testing, releasing, deploying, operating, and monitoring, fostering shared responsibility and agility.
DevSecOps	DevSecOps stands for development, security, and operations. DevSecOps environments integrate security practices and automation throughout the software development lifecycle, shifting security responsibilities to all team members, not just dedicated security specialists. This approach aims to identify and address security vulnerabilities early on, reducing risks and costs associated with security breaches. Key elements include shared responsibility for security, automation of security processes, and continuous monitoring and feedback.
Digital Twin (DT),	Digital Twin (DT), A digital twin is a virtual model that mirrors a physical object, system, or process, enabling real-time monitoring, simulation, and analysis. It acts as a digital counterpart, allowing users to interact with and understand the physical world through a virtual lens.
Digital Twin Triplet (DT3),	A Digital Twin Triplet (DT3) extends the concept of a Digital Twin by integrating a third entity, often a human or a semi-physical system, to create a more comprehensive and interactive representation of a physical object or system. This third entity acts as a bridge between the physical and virtual worlds, enhancing the functionality and usability of the digital twin.

Abbreviation or Term	Meaning and Explanation
Electronic design automation (EDA)	Electronic design automation (EDA) is a set of software, hardware, and essential services for designing chips and semiconductor devices. In the past, hardware architects used to sketch chip designs by hand and utilized siloed tools. However, with the billions of connections and multiple teams, the role of EDA is crucial in the hardware creation process. EDA is a simulated world where the circuits and designs are conceived and analyzed before making it to the real world. EDA has evolved with the meteoric rise of artificial intelligence (AI) .
EMI	Electromagnetic interference (EMI) is unwanted noise or interference in an electrical path or circuit caused by an outside source.
GenAI	Generative AI: Technology that creates content including text, images, video, and computer code by identifying patterns in large quantities of training data and then creating original material with similar characteristics
Generative Adversarial Networks (GAN)	GAN stands for generative adversarial network. It's a type of machine learning model called a neural network, specially designed to imitate the structure and function of a human brain. For this reason, neural networks in machine learning are sometimes referred to as artificial neural networks (ANNs). This technology is the basis of deep learning, a subcategory of machine learning capable of recognizing complex patterns in varying data types such as images, sounds, and text.
Heuristics	A heuristic or heuristic technique is any approach to problem solving that employs a pragmatic method that is not fully optimized, perfected, or rationalized, but is nevertheless "good enough" as an approximation or attribute substitution.
Hidden Markov Models (HMMs)	Hidden Markov Models (HMMs) are probabilistic models used to analyze sequences of observations by inferring the underlying hidden states that generate those observations. They are often used when the underlying process that creates the data is not directly observable but can be modeled as a sequence of hidden states.

Abbreviation or Term	Meaning and Explanation
Industry 5.0	Industry 5.0, also known as the Fifth Industrial Revolution, is a concept that builds upon Industry 4.0 by emphasizing a human-centric, sustainable, and resilient approach to industrial production. It focuses on leveraging advanced technologies like AI and robotics alongside human expertise to create a more collaborative, ethical, and environmentally responsible industrial ecosystem.
IoT	Internet of Things (IoT) is a vast network of physical objects—from smart home devices and wearables to industrial sensors and vehicles—embedded with sensors, software, and connectivity to collect and exchange data over the internet or other networks, creating "smart" environments that enable automation, remote monitoring, and improved efficiency in homes, cities, healthcare, and industry.
K-Nearest Neighbors (KNN)	K-Nearest Neighbors (KNN) is a supervised machine learning algorithm used for both classification and regression tasks. It works by finding the "k" closest data points (neighbors) to a new, unclassified data point and then classifies it based on the majority class among those neighbors. In regression, it predicts by averaging the values of the k-nearest neighbors.
KRR	Knowledge Representation and Reasoning is a fundamental subfield of artificial intelligence (AI) focused on encoding information about the world in symbolic forms—such as ontologies, knowledge graphs, and logic—that computers can use to solve complex tasks, make inferences, and draw human-like conclusions. It enables AI systems to go beyond mere data processing to active reasoning, supporting applications like natural language processing and diagnostic systems.
LLM	Large Language Model (LLM): A type of neural network that learns skills, including generating prose, conducting conversations, and writing computer code by analyzing vast amounts of text from across the internet.
Long Short-Term Memory (LSTM)	Long Short-Term Memory (LSTM) is a type of Recurrent Neural Network (RNN) architecture designed to process sequential data and learn long-term dependencies, overcoming the vanishing/exploding gradient problem found in traditional RNNs. LSTMs achieve this with a complex memory cell structure containing a cell state for long-term memory and gates (input, forget, output) to selectively control the flow of information. These networks are widely used for tasks such as natural language processing, speech recognition, and time series forecasting.

Abbreviation or Term	Meaning and Explanation
Machine learning (ML)	Artificial intelligence is the broader field — it refers to machines designed to perform tasks that typically require human intelligence, such as reasoning, problem-solving, and decision-making. Machine learning, on the other hand, is a specific approach within AI. Instead of being manually programmed for every task, ML systems learn from data, recognizing patterns and improving their performance over time through experience.
Maintenance engineering	Maintenance engineering focuses on ensuring the reliable and efficient operation of equipment, machinery, and systems within a facility. Maintenance engineers install, troubleshoot, and repair various systems, from electrical and mechanical to automated ones, using their expertise to minimize downtime and maximize productivity. They may also be involved in developing maintenance strategies, managing budgets, and training maintenance technicians.
MAS	A multi-agent system (MAS) comprises multiple autonomous AI agents interacting within a shared environment to collaboratively solve complex tasks, often exceeding the capabilities of a single agent. Leveraging AI and sometimes Large Language Models (LLMs), these systems feature distributed decision-making, enabling enhanced scalability, adaptability, and efficiency in domains like logistics,, robotics, and customer service.
Materials Genome Initiative (MGI)	<u>About the Materials Genome Initiative</u> The Materials Genome Initiative is a federal multi-agency initiative for discovering, manufacturing, and deploying advanced materials twice as fast and at a fraction of the cost compared to traditional methods. The initiative creates policy, resources, and infrastructure to support U.S. institutions in the adoption of methods for accelerating materials development. Advanced materials are essential to economic security and human well-being, with applications in industries aimed at addressing challenges in clean energy, national security, and human welfare, yet it can take 20 or more years to move a material after initial discovery to the market. Accelerating the pace of discovery and deployment of advanced material systems will therefore be crucial to achieving global competitiveness in the 21st century.

Abbreviation or Term	Meaning and Explanation
MBSE Model-Based Systems Engineering	Model-Based Systems Engineering (MBSE) is a methodology that uses digital models as the primary means of representing and managing information throughout a system's lifecycle, from conception to decommissioning. It moves away from traditional document-centric approaches, emphasizing the use of models to define, design, analyze, verify, and validate complex systems.
Mechatronics	The synergetic integration of different engineering domains such as mechanics, electronics and information technology can create new products and stimulate innovative solutions.
Metaheuristic techniques	Metaheuristic techniques are a class of problem-solving methods used to find optimal or near-optimal solutions to complex problems, especially those that are difficult to solve with traditional algorithms. They are high-level strategies that guide the search process, often inspired by natural phenomena, and are widely used in various fields like engineering, logistics, and computer science.
Meta-learning is also known as "learning to learn,"	Meta-learning, also known as "learning to learn," is a machine learning approach where algorithms are trained to learn how to learn more efficiently on new, related tasks. Instead of training a model from scratch for each task, meta-learning focuses on developing models that can quickly adapt to new tasks with limited data, leveraging knowledge gained from previous learning experiences.
Model Context Protocol (MCP)	The Model Context Protocol (MCP) is an open standard and framework, introduced by Anthropic, that allows large language models (LLMs) to communicate with external data, applications, and tools, enabling them to access real-time information and perform actions beyond their training data for more accurate and useful AI agents. It acts as a universal translator between LLM "clients" and "servers" (like databases, search engines, or software), standardizing integrations to replace fragmented, custom connections.
Multiphysics	Multiphysics refers to the simultaneous simulation of multiple, interacting physical phenomena in a system, such as fluid flow, heat transfer, structural mechanics, and electromagnetics. It is a computational approach used in engineering and science to model and analyze complex systems where different physics are intertwined and influence each other.

Abbreviation or Term	Meaning and Explanation
Naive Bayes	Naive Bayes is a classification algorithm that uses Bayes' Theorem with the assumption of independence between features. It's considered "naive" because it simplifies computations by assuming features are independent of each other, given the class. Despite this simplification, it often performs well in various classification tasks, particularly in text classification, spam filtering, and sentiment analysis
Natural Language Processing for Requirements Engineering	NLP4RE (Natural Language Processing for Requirements Engineering) is an area of research and development that seeks to apply natural language processing (NLP) techniques, tools and resources to the requirements engineering (RE) process, to support human analysts to carry out various linguistic analysis tasks
Neuromorphic engineering	Neuromorphic engineering is a multidisciplinary field that creates artificial neural systems inspired by the structure and function of the human brain. It aims to develop computing systems that are more efficient, adaptable, and capable of learning, just like biological brains.
Ontology	An ontology is a formal representation of knowledge as a set of concepts within a specific domain and the relationships between them. It's a way to structure and organize information, making it understandable by both humans and machines. Think of it as a blueprint for a specific area of knowledge, defining the entities, their properties, and how they relate to each other.
Overfitting	Overfitting in Machine Learning (ML) is when a model learns its training data too well, including noise and irrelevant details, leading to poor performance on new, unseen data because it fails to generalize. Causes include complex models or insufficient training data, and it's indicated by excellent training performance and poor validation/test performance. Strategies to combat overfitting involve using a test dataset, employing regularization techniques, and cross-validation, among others.
PaLM - Pathways Language Model	The Pathways Language Model is the name of a family of AI large language models developed by Google. The effort gets its name from a Google Research initiative to create what researchers dubbed <i>pathways</i> , in an approach designed to build a single powerful model that could serve as a foundation for multiple use cases.

Abbreviation or Term	Meaning and Explanation
Physics-informed neural operators (PINO)	Physics-informed neural operators (PINO) is a machine learning method that combines data-driven operator learning with physics constraints to learn the solution operators of partial differential equations (PDEs). It leverages the strengths of both data-driven and physics-based approaches, offering a hybrid framework for solving complex PDEs. PINO utilizes the Fourier Neural Operator (FNO) framework, which is known for its ability to learn mappings between function spaces, and incorporates PDE constraints to improve accuracy and generalization, particularly in scenarios with limited or no training data.
Predictive maintenance (PdM)	Predictive maintenance (PdM) is a maintenance strategy that uses data analysis to anticipate equipment failures and schedule maintenance before they occur. It involves monitoring equipment performance through sensors and other data sources, then using that data to predict when a failure is likely to happen. This allows for proactive maintenance, minimizing downtime and maximizing the lifespan of equipment.
Quality engineering (QE)	Quality engineering (QE) is a discipline focused on ensuring products or services meet specified standards and customer expectations by integrating quality principles throughout the development lifecycle. It's a proactive approach that emphasizes preventing defects rather than just finding them, aiming for continuous improvement and efficient processes. In software development, QE involves rigorous testing, data-driven analysis, and embedding quality considerations from the initial design phase to deployment and maintenance.
Recurrent Neural Networks (RNNs)	Recurrent Neural Networks (RNNs) are a type of deep learning model designed to process sequential data, such as text, speech, or time series, by incorporating memory through feedback loops. At each step, an RNN takes the current input and a "hidden state" (information from previous steps) to produce an output and update the hidden state, allowing it to learn long-term dependencies and contextual information within the sequence. Key applications include language translation, sentiment analysis, speech recognition, and time-series prediction.
Reinforcement learning (RL)	Reinforcement learning (RL) is a machine learning paradigm where an agent learns to make decisions in an environment to maximize a cumulative reward signal. It's a feedback-based approach where the agent interacts with the environment, takes actions, and receives rewards, learning from these interactions to improve its decision-making strategy. Unlike supervised learning, RL doesn't require labeled data and focuses on optimizing long-term outcomes.

Abbreviation or Term	Meaning and Explanation
Reliability engineering	Reliability engineering is a discipline focused on ensuring that products, systems, and processes perform their intended functions reliably and consistently over time, minimizing failures and downtime. It involves identifying potential failure points, analyzing their causes, and implementing measures to prevent or mitigate them. This field aims to improve the overall performance, durability, and efficiency of systems by integrating proactive design, data analysis, and proven maintenance strategies.
RTL	RTL , or Register Transfer Level , is the stage in digital circuit design where engineers describe how data moves between registers under the control of a clock signal. It's like scripting the traffic flow inside a city — the roads (data paths), signals (control logic), and rules (timing).
Supervised Learning (SL),	Supervised learning (SL), is a machine learning technique that uses human-labeled input and output datasets to train artificial intelligence models. The trained model learns the underlying relationships between inputs and outputs, enabling it to predict correct outputs based on new, unlabeled real-world input data.
A System of Systems (SoS)	A System of Systems (SoS) is a collection of independent, heterogeneous systems that are integrated to achieve a common, higher-level goal. These systems retain their individual identities and management structures but collaborate to provide capabilities beyond what any single system could achieve on its own. SoS are characterized by their scale, complexity, and the need for effective integration and coordination among diverse, often independently managed, systems.
TensorFlow and PyTorch	TensorFlow and PyTorch are two prominent open-source machine learning frameworks widely used for developing and deploying deep learning models. Both offer comprehensive tools and libraries for tasks such as computer vision, natural language processing, and more. TensorFlow: traditionally used a static computational graph, defined before execution and then optimized. While this can lead to performance advantages in large-scale production, it can be less intuitive for debugging. However, TensorFlow has increasingly adopted eager execution and Keras, which offer a more dynamic and Pythonic experience. PyTorch: uses a dynamic computational graph, which is built on the fly during execution. This offers flexibility and ease of debugging, making it popular for research and rapid prototyping.

Abbreviation or Term	Meaning and Explanation
Transformers	Transformers are a powerful deep learning architecture for handling sequential data, known for their attention mechanism, which allows them to weigh the importance of different parts of the input at once rather than sequentially. This enables models to understand context and long-range dependencies, leading to significant advances in natural language processing (NLP), computer vision, and other fields. Key components include an encoder and a decoder, and they are the foundation for large language models (LLMs) like GPT.
Unsupervised Learning (UL)	Unsupervised learning (UL) is a framework in machine learning where, in contrast to supervised learning, algorithms learn patterns exclusively from unlabeled data. Other frameworks in the spectrum of supervision include weak- or semi-supervision, where a small portion of the data is tagged, and self-supervision.
XAI	Explainable Artificial Intelligence (XAI) Explainable AI (XAI) refers to methods and processes that help humans understand and trust the decisions and outputs of AI systems, moving beyond the "black box" problem where complex algorithms' inner workings are opaque. XAI techniques provide transparency into how models arrive at predictions, enabling debugging, ensuring fairness, meeting regulations, improving security, and fostering user confidence, crucial for adopting AI in sensitive areas like healthcare, finance, and autonomous vehicles.

2. מתודולוגיה

סקירת ספרות זו משתמשת בגישה שיטתית ומובנית לזיהוי, בחירה וניתוח פרסומים אקדמיים ומקצועיים רלוונטיים הנוגעים לשילוב יישומי בינה מלאכותית (AI) בהנדסת מערכות ובתחומי הנדסה רחבים יותר. המתודולוגיה נועדה להבטיח הן מקיפות והן רלוונטיות, תוך התמקדות בהבנת האבולוציה של יישומי בינה מלאכותית במהלך השנים האחרונות, עם דגש ספציפי על התקופה שבין 2018 ל-2025. מסגרת זמן זו נבחרה כדי לשקף את ההתקדמות העדכנית ביותר בבינה מלאכותית ואת תפקידה הגובר בפרקטיקה ההנדסית, בחינוך ובמחקר.

אסטרטגיית החיפוש כללה שאילתות במגוון מאגרי מידע אקדמיים וספריות דיגיטליות, כולל IEEE Xplore, Google Scholar, Scopus, ScienceDirect, SpringerLink, Web of Science. מילות מפתח ושילובים בוליאניים ששימשו בחיפוש כללו: "בינה מלאכותית", "יישומי בינה מלאכותית", "הנדסת מערכות", "הנדסה", "למידת מכונה", "למידה עמוקה", "מערכות חכמות", "תכן הנדסי" ו"בינה מלאכותית במערכות הנדסיות". מסננים יושמו כדי להגביל את התוצאות למאמרים בכתבי עת שעברו ביקורת עמיתים, מאמרי כנסים ודוחות איכותיים של מכוני מחקר ושל תעשיות מובילות שפורסמו בין ינואר 2018 לאוגוסט 2025.

קריטריונים של הכללה נקבעו כדי לבחור מקורות אשר (א) דנים בטכניקות בינה מלאכותית (למשל, למידת מכונה, רשתות עצביות, עיבוד שפה טבעית, מערכות מומחים, למידת חיזוק) המיושמים בתחומי הנדסת מערכות או הנדסה כללית; (ב) מספקים תובנות מושגיות, מתודולוגיות או אמפיריות לגבי שילוב בינה מלאכותית בתהליכים הנדסיים כגון תכן, מידול, סימולציה, אימות, אופטימיזציה או קבלת החלטות; ו-(ג) כתובים באנגלית. קריטריונים של הדרה שללו פרסומים שלא היו רלוונטיים ישירות להקשרים הנדסיים, תיאורטיים בלבד ללא יישום הנדסי, או חסרו קפדנות מדעית.

בסך הכל זוהו בתחילה כ-150 מאמרים. לאחר סינון תקצירים ויישום קריטריונים של הכללה/הדרה, נבחרו כ-60 מקורות מרכזיים לניתוח מעמיק. אלה סווגו באופן תמטי לפי תחום היישום שלהם (למשל, תעופה וחלל, אזרחי, מכני, חשמל), מתודולוגיית הבינה המלאכותית והשלב במחזור החיים של הנדסת המערכות אליו הם עוסקים (למשל, ניתוח דרישות, תכן מערכת, בדיקות, תפעול או תחזוקה).

תהליך הסינתזה כלל ניתוח תמטי איכותני כדי לזהות דפוסים חוזרים, פערים במחקר ומגמות מתפתחות. תשומת לב מיוחדת ניתנה לאופי הבין-תחומי של המחקר, לבשלות הטכנולוגיות ולאתגרים המעשיים של יישום במערכות הנדסיות בעולם האמיתי. מתודולוגיה מובנית זו מבטיחה שסקירת הספרות מספקת סקירה מאוזנת, רלוונטית ועדכנית של שילוב הבינה המלאכותית בהנדסת מערכות והנדסה.

הערה: ברשימת המקורות יש כ-160 מקורות שלחלקם יש התייחסות מפורשת וחלקם מובא לעיון הקורא.

3. תקציר

תהליכי תכן הנדסה וייצור מערכות מתקדמות כרוכים באתגרים רבים, כגון דינמיות והתנהגויות לא מתוכננות שיכולות להיות כאוטיות ומורכבות. לאחרונה, התפתחות של טכנולוגיות מידע עתק (ביג דאטה), מהירות חישוב גבוהה, מחשוב ענן וטכניקות בינה מלאכותית (כמו למידת מכונה ולמידה עמוקה) שינו את האופן שבו אנשי מקצוע רבים בתחום ההנדסה והייצור ניגשים לעבודתם. טכנולוגיות אלו מציעות דרכים חדשניות עבור מהנדסים ויצרנים להתמודד עם אתגרים מהחיים האמיתיים. תחום הבינה המלאכותית (AI) הוא תחום נרחב. קיימות תיאוריות, אלגוריתמים ושיטות מגוונות, מה שמציב אתגרים בבחירת טכניקת הבינה המלאכותית הנכונה לתהליך ההנדסי או תהליך הייצור המתאים וסביבותיו.

לאחר שעברה את השלבים הראשוניים והחלה לחולל מהפכה בתחומים רבים ושונים, בינה מלאכותית נמצאת בדרכה להפוך לטכנולוגיה פורצת דרך. היא צפויה גם לשנות לחלוטין גישות תכן הנדסי מסורתיות הממוקדות באדם. למרות שהם עדיין בשלבים המוקדמים, יישומי הנדסה המונעים על ידי בינה מלאכותית מאפשרים לעבוד עם פרמטרי תכן מעורפלים ולפתור בעיות הנדסיות מורכבות, שלא היו אפשריות אחרת בשיטות תכן מסורתיות. עבודה זו של סקר ספרות מנסה להאיר את ההתקדמות הנוכחית ומגמות המחקר העתידיות ביישומי בינה מלאכותית במושגי תכן/תכן הנדסי. שיטות כגון למידת מכונה, אלגוריתם גנטי ולוגיקה עמומה (fuzzy logic) נבחנו בקפידה מנקודת מבט של תכן הנדסי. מחקרי תכן המונעים על ידי בינה מלאכותית סווגו ונבדקו באופן ביקורתי עבור שלבי תכן שונים כגון השראה, יצירת רעיונות וקונספט, הערכה, אופטימיזציה, קבלת החלטות ומידול. כתוצאה מסקירה זו, אנו יכולים לומר בביטחון שהעניין בשיטות תכן מבוססות נתונים ובינה מלאכותית מוסברת (XAI)¹ גבר בשנים האחרונות. יתר על כן, השימוש בשיטות בינה מלאכותית ביישומי תכן הנדסי מסייע בהשגת תוצאות יעילות, מהירות, מדויקות ומקיפות. במיוחד בעזרת שיטות ושילובים של למידה עמוקה, ניתן לטפל ביעילות במצבים בהם היכולת האנושית אינה מספקת. עם זאת, בחירת שיטת הבינה המלאכותית הנכונה לבעיית התכן הנדסית חשובה ומשמעותית לתוצאות מוצלחות. לפיכך, סיפקנו פרספקטיבה מתקדמת על בחירת שיטת הבינה המלאכותית הנכונה בהתבסס על תוצאות הספרות עבור בעיות תכן.

מדובר בעולם תוכן המשתנה ומתפתח במהירות ולכן חשוב להמשיך ולעקוב אחר הספרות הרלוונטית מופצת בכתבי עת שונים, בכנסים ובקהילות מחקר.

בהמשך מובאות התובנות הנובעות מסקר הספרות, השפעת הבינה המלאכותית (AI) על הנדסת מערכת, הנדסת מכונות, הנדסת אווירונאוטיקה, והנדסת חשמל/אלקטרוניקה, ונושאים חוצי-תחומים.

נושא מרכזי בסקר הספרות הוא תפקידה של הבינה המלאכותית לא רק כמשפרת יעילות אלא גם כזרז ליצירתיות בהנדסה ובהנדסת מערכות. באופן מסורתי, יצירתיות בתכן הנדסי הוגבלה על ידי מגבלות קוגניטיביות אנושיות, לחצי זמן והקושי לחקור מרחבי תכן עצומים עם משתנים תלויים זה בזה. כלי בינה מלאכותית משנים נוף זה בהיותם שותפים יצירתיים, המאפשרים למהנדסים לייצר, להעריך ולשפר רעיונות בקנה מידה ובמהירויות שהיו בלתי אפשריות בעבר. אלגוריתמים של תכן גנרטיבי, למשל, יכולים להציע אלפי תצורות חלופיות המבוססות על דרישות מוגדרות, ולחשוף פתרונות חדשניים שמעצבים אנושיים אולי מעולם

¹ Explainable Artificial Intelligence (XAI)

לא שקלו. מודלים של שפה טבעית יכולים לסייע בסיעור מוחות של מושגים, מסגור מחדש של בעיות או סינתזה של ידע בין תחומים, ולתמוך במהנדסים ביצירת קשרים חדשים. עבור מהנדסי מערכות, שתפקידם דורש איזון בין מורכבות, שילוב תת-מערכות מרובות וציפייה להתנהגויות מתפתחות, בינה מלאכותית מציעה יכולות, סימולציה וניתוח תרחישים, חזקות המעוררות דרכים חדשות לחשיבה על פשרות וארכיטקטורות. יתר על כן, סביבות תכן מונעות על ידי בינה מלאכותית משחררות מהנדסים ממשימות חוזרות ונשנות, ומאפשרות להם להקדיש יותר אנרגיה לאתגרים יצירתיים מסדר גבוה יותר כמו חדשנות קונספטואלית (רעיונית) ואסטרטגיה ברמת המערכת. **חשוב לציין, בינה מלאכותית אינה מחליפה את דמיונו של המהנדס אלא מרחיבה אותו - פועלת כמכפיל של כושר ההמצאה האנושי. על ידי שילוב בינה מלאכותית בתהליך היצירה, מהנדסים ומהנדסי מערכות יכולים להתקדם מעבר לשיפורים הדרגתיים לעבר פתרונות טרנספורמטיביים באמת, למקם את עצמם בחזית ההתקדמות הטכנולוגית ולהבטיח שתכן הנדסי יתפתח בהתאם לדרישות המאה ה-21.**

3.1. סיכום התובנות המרכזיות בכל אחד מתחומי ההנדסה הנובעות מסקר הספרות

השפעת הבינה המלאכותית (AI) על הנדסה והנדסת מערכות היא עמוקה ומתפתחת במהירות. להלן פירוט התובנות המרכזיות במגוון ממדים:

1. טרנספורמציה של תכן ופיתוח הנדסי

- בינה מלאכותית מאיצה תהליכי תכן: כלים כמו תכן גנרטיבי (תכן יוצר) משתמשים באלגוריתמים של בינה מלאכותית כדי לייצר חלופות תכן מרובות וממוטבות המבוססות על אילוצים ויעדים.
- סימולציה ומידול משופרים באמצעות בינה מלאכותית כדי לחזות ביצועים, לזהות פגמים ולבצע אוטומציה של תהליכים איטרטיביים (מחזוריים) או ספירליים, במיוחד במערכות מורכבות (למשל, תעופה וחלל, רכב, אלקטרוניקה, מערכות נשק).

2. שיפור הנדסת מערכות

- שילוב מערכות משופר: בינה מלאכותית מסייעת בניהול מורכבות על ידי אופטימיזציה של ממשקים ואינטראקציות במערכות בקנה מידה גדול (למשל, הגנה, ייצור, תחבורה).
- הנדסת מערכות מבוססת מודלים (MBSE)² מתפתחת עם תאומים דיגיטליים מבוססי בינה מלאכותית, המאפשרים ניטור, בדיקות ותחזוקה חזויה בזמן אמת.
- ככל שבינה מלאכותית (AI) ממשיכה להתפשט בתעשיות שונות, יש לגשת ליישומה במערכות קריטיות למשימה כמו תעופה וחלל וביטחון בדיוקנות ובזהירות. בלב השילוב הזה טמונה הנדסת מערכות מבוססת מודלים (MBSE), גורם מפתח המאפשר הנדסה דיגיטלית. כאשר משלבים אותן בצורה מושכלת, MBSE ובינה מלאכותית יכולות לשנות את האופן שבו מערכות מורכבות מתוכננות, מאומות

² Model-Based Systems Engineering (MBSE)

ונפרסות. עם זאת, מימוש ערך זה דורש הבנה מעמיקה של המגבלות והסיכונים של הבינה המלאכותית, ומחויבות חזקה לשמירה על פיקוח אנושי.

החיבור בין בינה מלאכותית להנדסת מערכות הוביל לשתי גישות משלימות: "בינה מלאכותית להנדסת מערכות" (AI4SE) ו"הנדסת מערכות לבינה מלאכותית" (SE4AI). AI4SE כולל יישום טכניקות של בינה מלאכותית כגון מודלים של שפה גדולה (LLMs) (תת-קבוצה של למידה עמוקה) ו/או עיבוד שפה טבעית (NLPs) כדי לשפר את היעילות והאוטומציה של משימות הנדסת מערכות. SE4AI, לעומת זאת, משתמש במתודולוגיות הנדסת מערכות מובנות כדי להגדיר את ההקשר ולשפר את ההסבר והמעקב אחר פריסות בינה מלאכותית. התמקדות מאוזנת בשתייה נחוצה כדי להשיג טרנספורמציה דיגיטלית חזקה ואחראית [1].

3. שינוי בתפקידים ובמיומנויות

- מהנדסים חייבים לרכוש מיומנויות הקשורות לבינה מלאכותית כגון ניתוח נתונים, למידת מכונה ותכנות ודגש על חשיבה ביקורתית. יהיה דגש הולך וגובר על דיוק בשלב הגדרת הדרישות ועל בחינה ביקורתית של תוצרי הבינה המלאכותית.
- יש ביקוש גובר לאנשי מקצוע היברידיים: מהנדסים בעלי חשיבה מערכתית שמבינים ארכיטקטורות של בינה מלאכותית ויכולים ליישם אותן על בעיות הנדסיות מסורתיות.

4. אוטומציה ותמיכה בקבלת החלטות

- בינה מלאכותית מאפשרת מערכות אוטונומיות (למשל, רחפנים, כלי רכב אוטונומיים) וקבלת החלטות חכמה במערכות בזמן אמת (למשל, רשתות חשמל, לוגיסטיקה).
- מהנדסים מסתמכים יותר ויותר על כלים המופעלים על ידי בינה מלאכותית לצורך אבחון, ניתוח גורמי שורש ואופטימיזציה של ביצועים.

5. פרודוקטיביות משופרת וחדשנות

- משימות שגרתיות (למשל, תיעוד, בדיקות איכות, יצירת קוד) עוברות אוטומציה.
- בינה מלאכותית משמשת ככוח עזר בחדשנות, ועוזרת למהנדסים לחקור פתרונות רבים יותר מהר יותר ובדיוק רב יותר.

6. הנדסת מחזור חיים ואמינות

- בינה מלאכותית משפרת תחזוקה חזויה וניהול בריאות הנכסים הן במערכי יצור, למשל מכונות CNC, והן מערכות בשימוש מבצעי באמצעות נתוני חיישנים ואלגוריתמים של למידת מכונה.
- בהנדסת מערכות, בינה מלאכותית מסייעת בהערכת עלויות מחזור חיים, ניתוח סיכונים ומעקב אחר דרישות.

7. אתגרים ושיקולים אתיים

- קיימות חששות בנוגע לשקיפות, אחריות ואמון במערכות המונעות על ידי בינה מלאכותית.
- הבטחת נוכחות אנושית נותרה קריטית עבור מערכות הנדסיות בעלות סיכון גבוה (למשל, שירותי בריאות, תעופה, ביטחון). הנוכחות האנושית חשובה במקרה שיש כשל מערכות ונדרש טיפול מיידי.

- הסברתיות של מודלים של בינה מלאכותית הוא אתגר הולך וגובר בתחומים מוסדרים (פיתוח תרופות, פיתוח מכשור רפואי) וקריטיים לבטיחות.
- 8. שיתוף פעולה בין-תחומי
- בינה מלאכותית בהנדסה דורשת שיתוף פעולה הדוק בין מומחים בתחום, מדעני נתונים ומהנדסי תוכנה.
- חינוך הנדסי צריך להשתנות על מנת לייצר אנשי מקצוע המסוגלים לעבוד בצומת שבין בינה מלאכותית, הנדסת מערכות ומומחיות בתחום.

סיכום

בינה מלאכותית אינה מחליפה מהנדסים אלא משפרת את יכולותיהם, ומאפשרת תכן, בנייה וניהול של מערכות חכמות, מהירות ומורכבות יותר. מהנדסי מערכות, בפרט, נהנים מיכולתה של בינה מלאכותית להתמודד עם מורכבות, אי ודאות והתנהגויות דינמיות לאורך מחזור חיי המערכת. עם זאת, הדבר מחייב גם שינוי תרבותי וחינוכי לעבר שיטות הנדסיות ממוקדות נתונים ומשולבות תוכנה.

3.2. השפעת הבינה המלאכותית (AI) על הנדסת מכונות, הנדסת אווירונאוטיקה, והנדסת חשמל/אלקטרוניקה.

הנדסת מכונות - השפעות עיקריות:

1. עיצוב יוצר ואופטימיזציה של טופולוגיה.
 - אלגוריתמי בינה מלאכותית חוקרים אלפי פרמוטציות עיצוב, וממטבים אותן לחוזק, משקל ועלות.
 - דוגמה: מערכת [Fusion 360](#) של Autodesk משלבת בינה מלאכותית לעיצוב יוצר (גנרטיבי).
2. תחזוקה חזויה ותאומים דיגיטליים
 - מודלים של למידת מכונה מנתחים נתוני רטט, טמפרטורה ואקוסטיקה כדי לחזות כשלים בציד.
 - דוגמה של מקרה שימוש בפועל: חברת סימנס וחברת-GE משתמשות בתאומים דיגיטליים המופעלים על ידי בינה מלאכותית כדי לדמות התנהגות של טורבינה ומנוע.
3. ייצור חכם ורובוטיקה
 - רובוטים מבוססי בינה מלאכותית מבצעים בדיקה, ריתוך והרכבה בדיוק משופר.
 - שילוב עם האינטרנט של הדברים (IoT) לבקרת איכות בזמן אמת.

הנדסת אווירונאוטיקה - השפעות עיקריות:

1. מערכות אוטונומיות וניווט

- בינה מלאכותית מאפשרת לרחפנים ולכלי טיס אוטונומיים לקבל החלטות ניווט ומשימה ללא מעורבות אנושית.
- דוגמה: "מעבדת האוטונומיה" של בואינג מתמקדת בכלי טיס המונעים על ידי בינה מלאכותית.

Autonomous capabilities

<https://www.boeing.com/innovation#anchor2>

Boeing funds autonomous aerial vehicle lab at Stanford

<https://verticalmag.com/news/boeing-funds-autonomous-aerial-vehicle-lab-stanford/>

The Boeing Flight & Autonomy Laboratory

<https://aa.stanford.edu/research-impact/labs-and-centers/boeing-flight-autonomy-laboratory>

2. גילוי תקלות וניטור תקינות

- מודלי ML מנתחים נתוני חיישנים ממנועים ומשלדות מטוסים לצורך גילוי אנומליות וניטור תקינות ניבוי. כאן הכוונה לתחזוקה חזויה.
- גילוי תקלות וניטור תקינות בהנדסת אווירונאוטיקה הוא תהליך קריטי להבטחת בטיחותם ואמינותם של כלי טיס.

3. סימולציה ואופטימיזציה של מערכות מורכבות

- בינה מלאכותית מפחיתה את הנטל החישובי של סימולציות מרובות תופעות פיזיקליות³ (למשל, CFD, ניתוח מבני)⁴.
- מודלים חלופיים שאומנו עם בינה מלאכותית מחליפים פותרנים פיסיקליים מסורתיים בלולאות תכן.

הנדסת חשמל ואלקטרוניקה - השפעות עיקריות:

אחד החיבורים המדהימים ומעוררי ההשראה הגדולה ביותר בתחום המקצועי הוא בין הנדסת אלקטרוניקה לבינה המלאכותית. החיבור הזה יוצר כיום שלל אפשרויות פיתוח מתקדמות – ממכשור צבאי ועד מכשור רפואי, מרכב אוטונומי ועד רובוטיקה תעשייתית.

³ Multiphysics, in the context of computational modeling, refers to the simultaneous simulation of multiple interacting physical phenomena within a system.

⁴ Computational Fluid Dynamics (CFD)

1. בינה מלאכותית בתכן ואימות מעגלים

- כלים כמו DeepMind של חברת גוגל ו-Cerebrus של חברת Cadence משתמשים בלמידת חיזוקים כדי לייעל פריסות שבבים [106].
- בינה מלאכותית מאיצה תכן ואימות בשיטות RTL וסינתזה לוגית⁵.

2. רשתות חכמות ואלקטרוניקה של הספק

- בינה מלאכותית חוזה את ביקוש העומס, משלבת אנרגיה מתחדשת וממטבת את ביצועי הרשת.
- המורכבות הגוברת של מערכות חשמל מחייבת אסטרטגיות מתקדמות לגילוי תקלות ותחזוקה חזויה כדי לשפר את יעילות התפעול ואת אמינות הרשת. גישות תחזוקה מסורתיות, כגון תחזוקה תגובתית ותחזוקה מונעת, הוכחו כלא מספיקות בהפחתת הפסקות לא מתוכננות ובאופטימיזציה של ניצול הנכסים. התקדמות אחרונה בבינה מלאכותית (AI) הציגה פתרונות מונחי נתונים המשפרים משמעותית את סיווג התקלות, חיזוי הכשלים ותהליכי התאוששות אוטומטיים [107].

3. בינה מלאכותית משובצת ומחשוב קצה

- שילוב מודלים של בינה מלאכותית בחומרה משובצת⁶ (למשל, NVIDIA Jetson, מאיצי בינה מלאכותית, ARM Cortex-M) עבור IoT, רובוטיקה ובקרה בזמן אמת.
- דוגמה מקרה בשימוש: חיישנים המופעלים על ידי בינה מלאכותית בכלי רכב אוטונומיים או רחפנים.

3.3. נושאים חוצי-תחומים

- חינוך והסבה מקצועית: מהנדסים בכל התחומים צפויים יותר ויותר להיות בקיאים בתוכנות כמו Python, TensorFlow/PyTorch וכמו כן ניתוח נתונים ומידול מערכות.
- שיתוף פעולה בין אדם לבינה מלאכותית: מהנדסים פועלים כארכיטקטים ומתכננים של מערכות ומקבלי החלטות, בעוד שבינה מלאכותית מטפלת במשימות ניתוח, אופטימיזציה וניטור.

סיכום

בינה מלאכותית אינה מחליפה הנדסה מסורתית, אלא מעצימה את יכולות ההנדסה, משפרת את הדיוק, היעילות והחדשנות בתחומי המכניקה, התעופה והחלל, החשמל והאלקטרוניקה. מהנדסים שמסתגלים לכלים ותהליכי עבודה של בינה מלאכותית נמצאים בעמדה הטובה ביותר להובלה בפיתוח טכנולוגי עתידי.

⁵ RTL - Register Transfer Level - a digital hardware design abstraction that describes a circuit's behavior by modeling the flow of data between registers and the logical operations performed on that data, synchronized by a clock

⁶ Embedded system

4. סקירה כללית - שיטות וטכניקות של בינה מלאכותית

בפרק זה, אנו מציעים סקירה תמציתית של התחום המרתק של בינה מלאכותית ומדגישים את ההבדל העדין אך המשמעותי בין שיטות וטכניקות של בינה מלאכותית. המונחים "טכניקת בינה מלאכותית" ו"שיטת בינה מלאכותית" משמשים לעתים קרובות לסירוגין, מה שמוביל לבלבול במחקרים מסוימים. עם זאת, חיוני להבחין בין מונחים אלה שכן הדבר מעשיר את הבנתנו את הגישות המגוונות המועסקות בבינה מלאכותית. על ידי ההבדלה מושגים אלה, אנו שואפים לספק הבנה מדויקת ומקיפה יותר של הספקטרום הרחב של המתודולוגיות המשמשות לאורך מחזור החיים של מוצר. עבור אלו המעוניינים להעמיק בתחום הבינה המלאכותית. אנו ממליצים לקרוא פרסום שכותרתו היא - 9 יתרונות של בינה מלאכותית (AI) בשנת 2026 – שנכתב באוניברסיטת סינסינטי בארה"ב. בסקירה זו, המחברים מספקים תובנות רבות עניין לגבי טכנולוגיות בינה מלאכותית, אימוצן בתעשייה ובחברה, כמו גם היתרונות, האתגרים והחששות סביב יישומן [2].

במאמר שכותרתו היא: תפקיד הבינה המלאכותית בהנדסה: סקירה כללית (רון קנת, טים דייוויס) [158] כותבים החוקרים שלבינה מלאכותית ולמידת מכונה יש נוכחות בכל ההיבטים של הנדסה. למידת מכונה מאפשרת למערכות מיחשוב לבצע משימות הנדסיות ללא הנחיות ספציפיות של המהנדס. כמו כן, בינה מלאכותית מאפשרת ומסייעת לניתוחי נתונים (Data) מורכבים, כמו אופטימיזציה, חיזוי אנליטי, סימולציות, בנייה וניהול מודלים הנדסיים ותאומים דיגיטליים ועוד. השימוש בבינה מלאכותית גם מאפשר מעבר מהנדסת תכן לתכן של ביצועים.

4.1. סקירה כללית של בינה מלאכותית

בינה מלאכותית היא תחום מסקרן וטרנספורמטיבי במדעי המחשב, השואף לחקות אינטליגנציה דמוית אדם באמצעות מחשבים. היא כוללת מגוון רחב של טכניקות ואלגוריתמים המאפשרים למחשבים לבצע משימות שבדרך כלל דורשות אינטליגנציה אנושית, כגון למידה, חשיבה, פתרון בעיות וקבלת החלטות. התפתחות הבינה המלאכותית הייתה מהירה, מונעת על ידי התקדמות בכוח המחשוב, זמינות של מערכי נתונים עצומים וחדושים אלגוריתמיים מתמשכים.

הבחנה מהותית בתוך בינה מלאכותית היא החלוקה בין בינה מלאכותית חלשה לבינה מלאכותית חזקה כמו גם בינה מלאכותית יוצרת. בינה מלאכותית חלשה, המכונה לעתים קרובות בינה מלאכותית צרה, מתייחסת למערכות בינה מלאכותית המיועדות למשימות ויישומים ספציפיים. מערכות אלו מצטיינות בתחומים הייעודיים שלהן ויכולות להתעלות על בני אדם בתפקודים הייעודיים שלהן. דוגמאות לבינה מלאכותית חלשה כוללות עוזרות וירטואליות כמו Siri ו-Alexa, כלי תרגום שפות, מערכות שנותנות המלצות ותוכנות זיהוי פנים. למרות ביצועיהן המרשימים בתחומים שלהן, מערכות בינה מלאכותית אלו חסרות את היכולות הרחבות יותר הקשורות לאינטליגנציה כללית אנושית. לעומת זאת, בינה מלאכותית חזקה, המכונה גם בינה מלאכותית כללית (AGI)⁷, מייצגת שאיפה גבוהה יותר במחקר בינה מלאכותית. בינה מלאכותית שואפת ליצור מערכות בינה מלאכותית בעלות רמת אינטליגנציה כללית כמו זו של בני אדם, המאפשרת להן להבין, ללמוד ולהסתגל בתחומים מגוונים. השגת בינה מלאכותית חזקה נותרה מטרה שאפתנית ועדיין לא מומשה במלואה. פיתוח

⁷ Artificial General Intelligence (AGI)

בינה מלאכותית חדשה דורש הבנה מעמיקה של יכולת התפיסה וההבנה (הקוגניציה) האנושית, התודעה והיכולת להתמודד עם משימות מורכבות ולא מובנות.

בינה מלאכותית היא נושא רב-תחומי השואב מתחומים ונושאים מדעיים שונים כגון מדעי המחשב, למידה עמוקה, למידת מכונה, ביולוגיה אבולוציונית (אלגוריתמים אבולוציוניים), מערכות מומחים, עיבוד שפה טבעית, ראייה ממוחשבת, רובוטיקה ותכן. ככל שהבינה המלאכותית ממשיכה להתקדם, השפעתה משתרעת על פני תעשיות רבות, כולל שירותי בריאות, פיננסים, הנדסה, ייצור, תחבורה ובידור, תעשיות ביטחוניות שמפתחות פלטפורמות שונות וכלי נשק. היא הובילה ליישומים יוצאי דופן כגון כלי רכב אוטונומיים, ניתוח תמונות רפואיות, גילוי הונאות פיננסיות ועיבוד שפה טבעית. הפוטנציאל של בינה מלאכותית הוא עצום, ויש לה את היכולת לחולל מהפכה בהיבטים שונים של החברה ולשפר את חיי האדם באופן משמעותי. עם זאת, עם אימוצה הנרחב, בינה מלאכותית מעלה גם שאלות קריטיות בנוגע לאתיקה, הטיה, פרטיות נתונים ופריסה אחראית של טכנולוגיות בינה מלאכותית. התמודדות עם אתגרים אלה תהיה קריטית ברתימת מלוא הפוטנציאל של בינה מלאכותית לשיפור האנושות.

4.2. שיטות וטכניקות של בינה מלאכותית

המונחים "טכניקת בינה מלאכותית" ו"שיטת בינה מלאכותית" משמשים לעתים קרובות לסירוגין, אך קיים הבדל עדין ביניהם. בסעיף הבא נשתדל לספק הבהרה מפורטת.

4.2.1 שיטות בינה מלאכותית

שיטות בינה מלאכותית מייצגות את הגישות והפרדיגמות הבסיסיות המנחות את פיתוחן של מערכות חכמות. מתודולוגיות מקיפות אלו משמשות כתוכניות לפתרון בעיות ולרכישת ידע. כמה משיטות הבינה המלאכותית הבולטות כוללות:

1. למידת מכונה⁸ (ML): למידת מכונה היא שיטה מרכזית בבינה מלאכותית המאפשרת למכונות ללמוד מנתונים מבלי להיות מתוכננות במפורש. היא כוללת יצירת אלגוריתמים ומודלים שיכולים לזהות באופן אוטומטי דפוסים וקשרים בתוך הנתונים ולקבל תחזיות או החלטות על סמך דפוסים אלה. ניתן לסווג את למידת המכונה באופן כללי לשלושה ענפים עיקריים⁹: למידה מפקחת (SL), למידה לא מפקחת (UL) ולמידת חיזוק (RL).


איור 4.1 מציג את הטקסונומיה של אלגוריתמי למידת מכונה (ML) ואת הדוגמאות הנפוצות שלהם בספרות. 2. למידה עמוקה¹⁰ (DL): למידה עמוקה היא תת-קבוצה מיוחדת של למידת מכונה המשתמשת ברשתות עצביות מלאכותיות, בהשראת המבנה והתפקוד של המוח האנושי. רשתות עצביות עמוקות אלו מורכבות משכבות מרובות (ולכן ה"עומק") של צמתים (נוירונים) המחוברים זה לזה ומעבדים נתונים בצורה היררכית.

⁸ Machine learning (ML)

⁹ Supervised Learning (SL), Unsupervised Learning (UL), and Reinforcement Learning (RL).

¹⁰ Deep learning (DL)

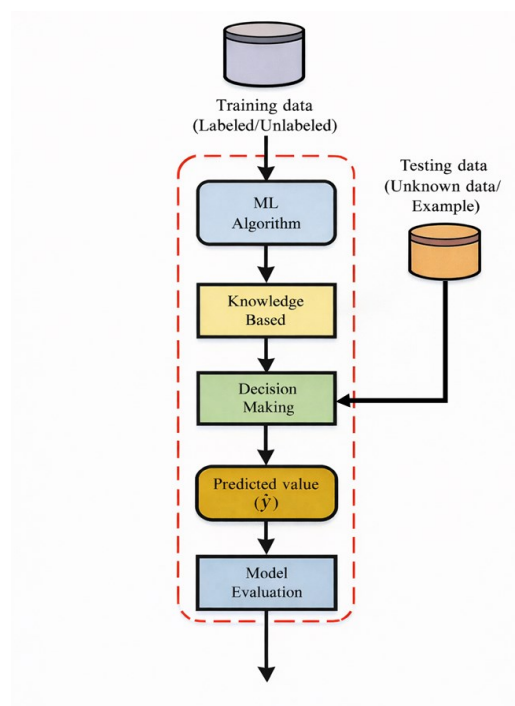
DL הראתה הצלחה יוצאת דופן במשימות כגון זיהוי תמונות, עיבוד שפה טבעית וסינתזת דיבור. יכולתה לעבד כמויות עצומות של נתונים לא מובנים, כמו תמונות וטקסטים, הופכת אותה ליעילה במיוחד בתחומי בעיות מורכבות ובעלות ממדים רבים.



איור 1-4 - טקסונומיה של אלגוריתמי ML בספרות (Source: ChatGPT)

סידור בסיסי של מערכת למידת מכונה (ML)

איור 4.2 מציג מבנה בסיסי של מערכת ML. נקבע יעד למידה, ועל סמך זה נאסף מערך נתונים (מתויג או לא מתויג) ממספר מקורות נתונים ומחולק לשניים (כלומר, נתוני אימון ונתוני בדיקה). בהתבסס על רצון הארגון, מאגר הידע מחליט על אלגוריתם ML המתאים ביותר למטרה הארגונית הנוכחית. הידע הנלמד על ידי אלגוריתם ML מהתבנית הנסתררת בנתוני האימון מיושם על נתוני הבדיקה (נתונים לא ידועים/דוגמה) כדי לבצע את החיזוי. הפלט החזוי של המודל מושווה לערכי הרצוי כדי למדוד את ביצועי המודל.



איור 2-4 – תהליך בסיסי בלמידת מכונה (Source: ChatGPT)

3. עיבוד שפה טבעית¹¹: NLP היא שיטת בינה מלאכותית המאפשרת למכונות להבין, לפרש וליצור שפה אנושית. אלגוריתמי NLP מנתחים ומעבדים נתוני טקסט ודיבור, והופכים אותם לפורמט שמכונות יכולות לעבוד איתו. טכנולוגיה זו חוללה מהפכה ביישומים כמו תרגום שפות, ניתוח סנטימנטים (ידוע גם בתור "כריית דעות או בינה מלאכותית של רגשות"), צ'אטבוטים ועוזרי קול. על ידי גישור על הפער בין שפה אנושית להבנת מכונה, NLP אפשר התאמה טבעית ואינטואיטיבית יותר בין אדם למכונה.

4. מערכות מומחים¹²: מערכות מומחים הן תוכנות בינה מלאכותית שנועדו לחקות את יכולות קבלת ההחלטות של מומחים אנושיים בתחומים ספציפיים. מערכות אלו מסתמכות על מערכת מבוססת כללים וייצוג ידע כדי לספק המלצות ופתרונות המבוססים על המומחיות הספציפית לתחום שלהן. מערכות מומחים מצטיינות בתחומים שבהם מומחיות אנושית היא קריטית, כגון אבחון רפואי, ניתוח פיננסי ופתרון בעיות טכניות מורכבות.

5. אלגוריתמים אבולוציוניים¹³: בהשראת עקרונות האבולוציה הדרוויניסטית, אלגוריתמים אבולוציוניים הם למעשה אלגוריתמים מתפתחים שמטייבים פתרונות באמצעות תהליך איטרטיבי שהוא למעשה היזון חוזר של התפתחות פתרונות מועמדים. באמצעות בחירת מוטציות של אופרטורים (מפעילים), והצלבה,

¹¹ Natural language processing (NLP)

¹² Expert systems

¹³ Evolutionary algorithms (EAs) are adaptive methods, which can be used to solve search and optimization problems, based on genetic processes of biological organisms.

אלגוריתמי אבולוציה חוקרים ומשפרים פתרונות פוטנציאליים לבעיות אופטימיזציה מורכבות. אלגוריתמים אלה הוכיחו את עצמם כיעילים ביישומים שונים, כולל אופטימיזציה, תכן הנדסי ומידול פיננסי.

6. למידת חיזוק¹⁴ (RL): למידת חיזוק מציגה את המושג של סוכנים המקיימים אינטראקציה עם סביבה ולומדים באמצעות ניסוי וטעייה. סוכנים מבצעים פעולות בסביבה ומקבלים משוב בצורת תגמולים או עונשים, המנחים את תהליך הלמידה שלהם. RL מתאים היטב למשימות בהן אין נתונים מתויגים זמינים, והסוכן חייב ללמוד מפעולותיו כדי להשיג מטרות ארוכות טווח. למידת חיזוק יושמה בהצלחה בתחומים כמו משחקי משחקים, רובוטיקה ומערכות אוטונומיות.

7. מודלים גרפיים הסתברותיים: מודלים גרפיים הסתברותיים, המשלבים תורת ההסתברות ותורת הגרפים, מציעים מסגרת מובנית לחשיבה תחת אי ודאות ולניתוח תלות מורכבת¹⁵.

8. למידה באמצעות העברה¹⁶: על ידי מינוף ידע ממשימה אחת לשיפור ביצועים במשימות קשורות, למידה באמצעות העברה מטפלת במחסור בנתונים ומקלה על למידה יעילה בתחומים מגוונים.

9. למידה עוינת¹⁷: למידה עוינת כוללת הן הגנה על מודלים של בינה מלאכותית מפני התקפות עוינות והן יצירת דוגמאות עוינות להערכת חוסן המודל.

10. אינטליגנציית נחילים¹⁸: בהשראת התנהגות קולקטיבית בטבע, אלגוריתמים של אינטליגנציית נחילים מאפשרים למערכות מבוזרות ומאורגנות עצמית לפתור בעיות בשיתוף פעולה.

4.2.2 טכניקות בינה מלאכותית

כדי להשלים את שיטות הבינה המלאכותית המקיפות הללו, טכניקות בינה מלאכותית שונות משמשות ככלים ואלגוריתמים ייעודיים המועסקים במסגרת המתודולוגיות הרחבות יותר. טכניקות אלו ממלאות תפקידים מרכזיים בהתמודדות עם אתגרים ספציפיים ובהשגת ביצועים מעולים במשימות ממוקדות. כמה טכניקות בינה מלאכותית מרכזיות כוללות:

1. רשתות עצביות קונבולוציוניות¹⁹ (CNN): CNN היא טכניקת למידה עמוקה שתוכננה במיוחד לניתוח תמונות ווידאו. היא משתמשת בשכבות קונבולוציוניות כדי לחלץ באופן אוטומטי דפוסים ותכונות משמעותיות מתמונות, מה שמאפשר משימות מדויקות כמו זיהוי אובייקטים, זיהוי תמונה ופילוח תמונה.

¹⁴ Reinforcement learning (RL)

¹⁵ Complex Dependencies

https://learn.microsoft.com/en-us/openspecs/windows_protocols/ms-cmrp/b98642ea-f1d3-44ef-8bdd-081d63a2cfc5

¹⁶ Transfer learning

¹⁷ Adversarial learning

¹⁸ Swarm intelligence

¹⁹ Convolutional neural networks (CNN)

2. רשתות יריבות גנרטיביות²⁰ (GAN): GAN היא טכניקת למידה עמוקה המורכבת משתי רשתות נוירונים, מחולל ומבחין, המאומנים כרשתות יריבות. המחולל מייצר נתונים סינתטיים, בעוד שהמבחין מנסה להבדיל בין נתונים אמיתיים לסינתטיים. תהליך זה מוביל ליצירת נתונים סינתטיים מציאותיים, המועילים ליישומים כמו סינתזת תמונות והגדלת נתונים.
3. מידול שפה: מידול שפה הוא טכניקת NLP²¹ המשמשת לחיזוי ההסתברות של רצף מילים במשפט. המודל של NLP ממלא תפקיד מכריע בהבנת שפה ויצירתה, ועוזר למכונות לייצר משפטים קוהרנטיים ורלוונטיים להקשר במשימות כמו תרגום מכונה ויצירת טקסט.
4. מערכות מבוססות כללים: מערכות מבוססות כללים הן טכניקות בתוך מערכות מומחים המסתמכות על קבוצה של כללי "אם-אז" כדי לקבל החלטות. כללים אלה מייצגים מומחיות אנושית וידע בתחום, ומאפשרים למכונות לספק המלצות ופתרונות בתחומים ספציפיים, כגון אבחון רפואי ופתרון תקלות.
5. אלגוריתמים גנטיים: אלגוריתמים גנטיים הם טכניקות במסגרת אלגוריתמים אבולוציוניים השואבות השראה מתהליך האבולוציה הביולוגית. על ידי פיתוח איטרטיבי ועידון של פתרונות מועמדים באמצעות בחירה, קרוסאובר (מעבר מצד לצד) ומוטציה, אלגוריתמים גנטיים מייצגים פתרונות לבעיות מורכבות בתחומי ההנדסה, האופטימיזציה והמימון.
6. למידת Q: זוהי טכניקה במסגרת למידה מחזקת, המשמשת לאימון סוכנים לקבלת החלטות בסביבות דינמיות. הסוכן לומד באמצעות ניסוי וטעייה ומתאים את פעולותיו על סמך משוב (ערכי Q) כדי למקסם את התגמולים לטווח ארוך, מה שהופך למידת Q למתאימה למשימות כמו משחקי וידאו וניווט אוטונומי.
7. לוגיקה מסדר ראשון: לוגיקה מסדר ראשון היא טכניקה במסגרת ייצוג ידע והיגיון אשר מנסחת קשרים לוגיים בין ישויות ועובדות. היא מספקת מסגרת לוגית לייצוג ידע והיגיון, חיונית ליישומים הדורשים הסקת מסקנות לוגיות מורכבות וקבלת החלטות.
8. רשתות בייסיאניות (Bayesian networks): זוהי טכניקה הפועלת תחת מודלים גרפיים הסתברותיים, אשר לוכדת קשרים הסתברותיים בין משתנים.
9. מודלים מאומנים מראש: מודלים מאומנים מראש הם טכניקות תחת למידה באמצעות העברה (המוגדר באנגלית כ- Transfer Learning) המשתמשות במודלים שנלמדו מראש על מערכי נתונים עצומים כדי לאתחל ולכוון מודלים עבור משימות ספציפיות. גישה זו חוסכת זמן ומשאבי חישוב ומשפרת את הביצועים במשימות היעד, מה שהופך אותה למועילה עבור יישומים עם נתוני אימון מוגבלים.
10. אופטימיזציה של מושבת נמלים²²: טכניקה תחת אינטליגנציית נחיל, הפותרת בעיות אופטימיזציה בהשראת התנהגות חיפוש מזון של נמלים.

²⁰ Generative adversarial networks (GAN)

²¹ NLP - stands for Natural Language Processing

²² Ant colony optimization

11. תמיכה במכונות וקטור²³ (SVM): תמיכה במכונות וקטור היא טכניקת למידה עוצמתית ומפוקחת המשמשת למשימות סיווג ורגרסיה²⁴. SVM מוצאת את ההיפר-מישור האופטימלי שמפריד בצורה הטובה ביותר בין מחלקות שונות במרחב הנתונים. היא פועלת על ידי מיפוי נתונים למרחב תכונות בעל ממדים רבים וזיהוי ההיפר-מישור עם המרווח המרבי בין המחלקות. SVM יושמה באופן נרחב בתחומים שונים, כולל זיהוי תמונות, סיווג טקסט וביואינפורמטיקה.

12. יער אקראי²⁵ (RF): יער אקראי הוא טכניקת למידה משותפת (אנסמבלית) המשתמשת בעצי החלטה מרובים כדי לבצע תחזיות. הוא בונה מספר רב של עצי החלטה במהלך תהליך האימון ומשלב את התפוקות שלהם כדי לייצר תחזית חזקה ומדויקת יותר. יער אקראי ידוע ביכולתו להתמודד עם נתונים בעלי מימדים רבים ולמתן התאמת יתר. הוא משמש בדרכי כלל במשימות כגון סיווג, רגרסיה ובחירת תכונות.

הערה: למידה אנסמבלית היא פרדיגמת למידת מכונה שבה לומדים מרובים מאומנים לפתור את אותה בעיה.

לסיכום, טכניקת בינה מלאכותית מתייחסת לאלגוריתם או גישה ספציפיים המשמשים לטיפול בבעיה מסוימת של בינה מלאכותית, בעוד ששיטת בינה מלאכותית מייצגת מערך מקיף יותר של טכניקות ואסטרטגיות המשמשות לפתרון סוגים רחבים יותר של אתגרי בינה מלאכותית. חשוב לציין כי סיווג טכניקות בינה מלאכותית לשיטות בינה מלאכותית ספציפיות לא תמיד יהיה פשוט, שכן יישומים רבים בעולם האמיתי, כגון ראייה, דיבור, תכן ורובוטיקה, כוללים לעתים קרובות שילוב של שיטות וטכניקות בינה מלאכותית מרובות כדי להשיג את התוצאות הרצויות. בחירת שיטות הבינה המלאכותית תלויה באופי הבעיה, בזמינות של נתונים מתוגמים ובמורכבות המשימות הכרוכות בכך. חיוני להכיר בכך שההבחנה בין שיטות וטכניקות בינה מלאכותית יכולה לפעמים להיות מטושטשת, ומחברים שונים עשויים להשתמש בטרמינולוגיה שונה בספרות. עם זאת, הבנת השיטות והטכניקות השונות הזמינות בתחום הבינה המלאכותית היא קריטית לסקירה מקיפה של היישומים של טכניקות בינה מלאכותית לאורך מחזור החיים של ציוד תעשייתי.

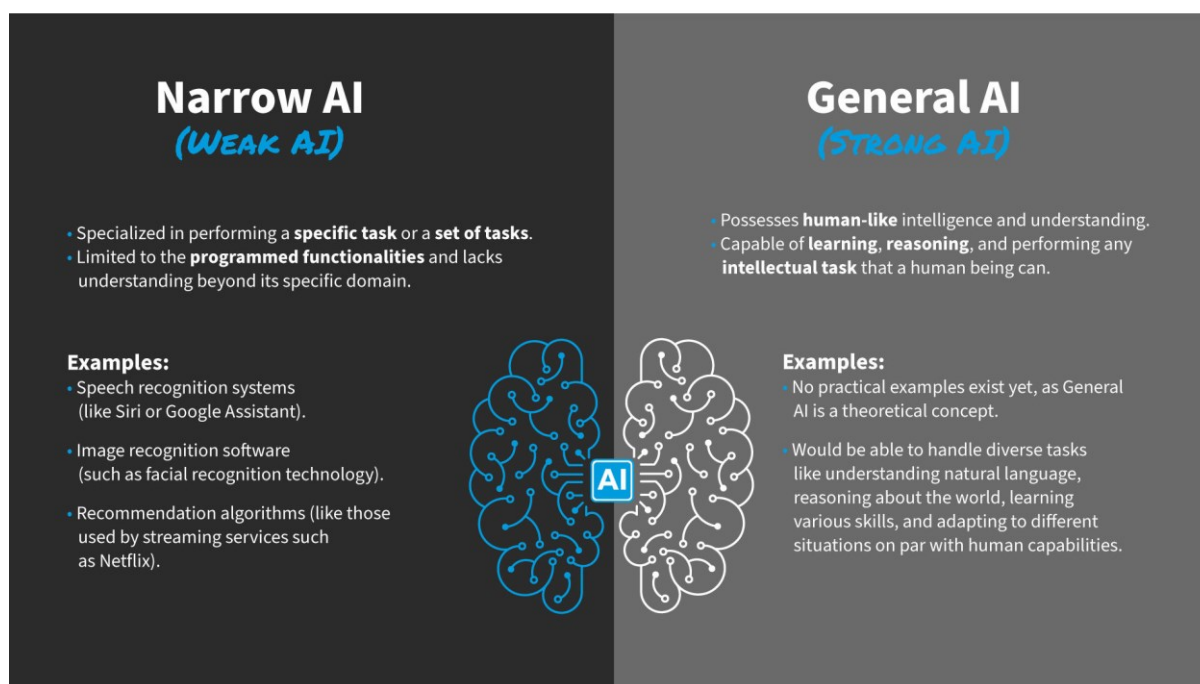
4.3. בינה מלאכותית כללית - General AI

בינה מלאכותית כללית [95,96,97], או בינה מלאכותית חזקה, מייצגת צעד משמעותי קדימה בתחום הבינה המלאכותית. מערכות בינה מלאכותית כללית יוכלו להבין, ללמוד וליישם ידע במגוון משימות, בדומה ליכולת ההסתגלות האנושית. נכון לעכשיו, לא קיימת בינה מלאכותית חזקה באמת. בעוד שבינה מלאכותית כללית היא מושג מבטיח, מערכות בינה מלאכותית עכשוויות, כולל אלו המסומנות כבינה מלאכותית חזקה, מתוארות בצורה מדויקת יותר כבינה מלאכותית צרה מתקדמת. לעומת זאת, בינה מלאכותית צרה מכווננת בקפידה למשימות ספציפיות, מציגה מומחיות בתחומים מוגדרים אך חסרה את יכולת ההסתגלות הרחבה שמגדירה את עתידה הצפוי של בינה מלאכותית כללית. איור 3-4 מתאר **בינה מלאכותית כללית מול צרה**.

²³ Support vector machines (SVM)

²⁴ Support Vector Machines

²⁵ Random forest (RF)



איור 3-4 - בינה מלאכותית כללית מול צרה

© Interaction Design Foundation, CC BY-SA 4.0

Source: <https://www.interaction-design.org/literature/topics/general-ai>

בינה מלאכותית כללית: מעבר להתמחות

בינה מלאכותית כללית משקפת חזון של יצירת מכונות בעלות יכולות קוגניטיביות הדומות לאלה של בני אדם. מערכות בינה מלאכותית כללית לא רק יבינו ויבצעו משימות ספציפיות, אלא גם יהיו בעלות היכולת להבין, ללמוד וליישם ידע על פני מגוון רחב של משימות, בדומה לגמישות הטבעה באינטליגנציה האנושית.

המאפיין המגדיר של בינה מלאכותית כללית טמון בחריגה שלה מהתמחות. בעוד שבינה מלאכותית צרה מצטיינת בגבולות של תחומים ספציפיים, בינה מלאכותית כללית חורגת מגבולות אלה ומדגימה יכולת הסתגלות, חשיבה ופתרון בעיות בהקשרים שונים. דמיינו ישות מלאכותית שיכולה לעבור בצורה חלקה מזיהוי דיבור למשחק שחמט, תרגום שפות ואפילו הבנת מושגים מופשטים.

גבולות תכן חדשים

עבור מתכננים, האפשרות של בינה מלאכותית כללית מציגה שינוי פרדיגמה בתהליך היצירה. בעוד שבינה מלאכותית צרה הוכחה כיעילה ביותר עבור יישומים ספציפיים, הרבגוניות של בינה מלאכותית כללית פותחת דלתות לאפשרויות תכן חדשות לחלוטין. דמיינו כלי תכן שלא רק מבין את העדפות המשתמש אלא גם צופה צרכים, לומד מאיטרציות עיצוב ומתאים את עצמו למגמות מתפתחות.

לבינה מלאכותית כללית יש פוטנציאל לחולל מהפכה בחוויות משתמש על ידי הצעת ממשקים מותאמים אישית ואדפטיביים החורגים מדפוסים מוגדרים מראש. מעצבים ומתכננים יכולים ליצור ממשקים המגיבים

לקלט המשתמש ומתאימים את עצמם באופן יזום על סמך התנהגות המשתמש, העדפותיו והבנתו את ההקשר של המוצר המתוכנן.

ככל שהבינה המלאכותית הכללית מתפתחת, מעצבים וגם מתכננים עשויים לעבוד לצד משתפי פעולה של בינה מלאכותית המסוגלים לתרום תובנות יצירתיות, להציע אלמנטים עיצוביים ואף להשתתף במפגשי גיבוש רעיונות. שיתוף פעולה זה בין בינה מלאכותית כללית למעצב יכול להאיץ את תהליך העיצוב, להציג נקודות מבט חדשניות ולשנות את האופן שבו מעצבים ניגשים לפתרון בעיות.

למרות שכמשתמשים טרם חוונו את המימוש המלא של מוצרים המונעים על ידי בינה מלאכותית כללית, חקירת ההשפעה הפוטנציאלית על עיצוב ותכנון מוצרים פותחת אפשרויות רבות. יכולת ההסתגלות וההבנה הרחבה הטבועות בבינה מלאכותית כללית עשויות לחולל מהפכה באופן שבו אנו תופסים, יוצרים ומקיימים אינטראקציה עם מוצרים.

אתגרים טכנולוגיים

החזון של בינה מלאכותית כללית מרתק, אך האתגרים הטכנולוגיים אדירים. על מנת להשיג קוגניציה ברמה אנושית, יש צורך בהתקדמות משמעותית בלמידת מכונה, עיבוד שפה טבעית והבנה עמוקה יותר של התודעה האנושית.

ההשפעה הפוטנציאלית של בינה מלאכותית כללית על תעסוקה, פרטיות ומבנים חברתיים מעלה דילמות אתיות. מעצבים חייבים להתמודד עם שאלות סביב פריסה אחראית של בינה מלאכותית והשלכותיה על יחידים וקהילות.

אם וכאשר בינה מלאכותית כללית תהפוך למציאות, מעצבים יצטרכו לבחון דרכים לאפשר שיתוף פעולה חלק בין בני אדם לישויות בינה מלאכותית. זה כולל כיצד לתכנן ממשקים אינטואיטיביים, ליצור ערוצי תקשורת ברורים ולהבטיח שמערכות בינה מלאכותית יחזקו את היכולות האנושיות ולא יחליפו אותן.

לסיכום אפשר לומר שבינה מלאכותית כללית נותרה מטרה שאפתנית ולא מציאות ממומשת במלואה.

הנוף הנוכחי של פיתוח בינה כללית מלאכותית (AGI) מאופיין בהתקדמות מהירה ועניין עולמי רב, המונעים על ידי פריצות דרך במודלי שפה גדולים, מערכות רב-מודאליות ולמידה בפקוח עצמי. בעוד שבינה כללית מלאכותית (AGI) אמיתית - בינה מלאכותית המסוגלת לחשיבה ברמת האדם על פני תחומים - טרם הושגה, ארגונים מובילים כמו OpenAI, DeepMind, Anthropic ואחרים דוחפים באופן פעיל את הגבולות לעבר בינה שניתנת יותר להכללה. המחקר מתמקד יותר ויותר בשיפור החשיבה, הזיכרון, יכולת ההסתגלות וההתאמת לערכים אנושיים. במקביל, חששות אתיים, רגולטוריים ובטיחותיים צוברים חשיבות, כאשר ממשלות וגופים בינלאומיים מתחילים לנסח מסגרות ניהול בינה מלאכותית לניהול הסיכונים הפוטנציאליים של AGI.

5. בינה מלאכותית בהנדסת מערכות

בינה מלאכותית (AI) ממלאת תפקיד קריטי יותר ויותר בשינוי הנדסת מערכות (SE), תחום שבאופן מסורתי מבוסס על מתודולוגיות דטרמיניסטיות ותהליכים ידניים. ככל שמערכות הופכות מורכבות יותר, מקושרות יותר ועתירות נתונים, בינה מלאכותית מספקת את הכלים הדרושים לניהול אי ודאות, אופטימיזציה של ביצועים ומאפשרת קבלת החלטות חכמה לאורך מחזור חיי המערכת. זה כולל תכן, אינטגרציה, בדיקות, תפעול ותחזוקה.

טכניקות בינה מלאכותית כגון למידת מכונה, עיבוד שפה טבעית, מערכות מומחים ואלגוריתמים אבולוציוניים משובצות כיום במשימות SE מרכזיות. שיטות אלו תומכות במידול ניבוי, ניתוח דרישות, זיהוי תקלות, אופטימיזציה ותמיכה בקבלת החלטות. גישות אחרות, כולל ייצוג ידע, לוגיקה מטושטשת (fuzzy logic), חשיבה הסתברותית ומערכות מרובות סוכנים, משפרות עוד יותר את היכולת למידול מורכבות ולהסתגל לסביבות משתנות. בינה מלאכותית גם תומכת בטכנולוגיות מתפתחות כמו תאומים דיגיטליים, ומאפשרת סימולציה, אבחון ואופטימיזציה בזמן אמת של מערכות סייבר-פיזיות²⁶.

שילוב זה של בינה מלאכותית והנדסת מערכות מעודדת מעבר מתכן סטטי מונחה מודלים לפיתוח ותפעול מערכות דינמיות מונחות נתונים. כתוצאה מכך, נדרשים מהנדסי מערכות לפתח מומחיות בין-תחומית המשלבת חשיבה מערכתית עם אוריינות בינה מלאכותית.

מערכות מורכבות, הכוללות לעתים קרובות יכולות מחשוב, מערכות מכניות ואלקטרוניקה, הן מאתגרות במיוחד לתכנון. ניתן להשתמש בבינה מלאכותית כדי לסייע למהנדסים לאורך כל תהליך התכנון, ואף ניתן להפוך משימות תכנון פחות קריטיות לאוטומטיות. ישנן 10 טכניקות המשמשות בהנדסת מערכות כמתואר להלן.

1. ייצוג ידע והיגיון (KRR- Knowledge Representation and Reasoning)
2. למידת מכונה (ML)
3. עיבוד שפה טבעית (NLP)
4. מערכות מומחים ומנועים מבוססי-כללים
5. אלגוריתמים אבולוציוניים ומטה-היוריסטיקה
6. תאומים דיגיטליים וסימולציה מונעת בינה מלאכותית
7. לוגיקה עמומה והיגיון הסתברותי
8. מערכות מרובות סוכנים (MAS- Multi-Agent Systems)
9. בינה מלאכותית עבור מערכות של מערכות (SoS)
10. מערכות תומכות החלטה מורכבות בינה מלאכותית

²⁶ Cyber-physical systems (CPS) are engineered systems that integrate computation, networking, and physical processes.

הסקירה הבאה בוחנת את טכניקות הבינה המלאכותית העיקריות המיושמות בהנדסת מערכות מודרנית, ממחישה מקרי שימוש מעשיים שלהן ומדגישה כיצד הן מעצבות את עתיד הנדסת מערכות חכמות, עמידות ואדפטיביות.

טכניקות בינה מלאכותית בהנדסת מערכות

הנדסת מערכות (SE) היא נושא רב-תחומי המתמקד בתכן, אינטגרציה וניהול של מערכות מורכבות לאורך מחזורי חייהן. הנדסת מערכות, ששורשיה הן באופן מסורתי במתודולוגיות קפדניות ומסגרות מובנות, התפתחה משמעותית עם הופעתן של טכנולוגיות דיגיטליות. בין אלה, בינה מלאכותית (AI) בולטת ככוח טרנספורמטיבי. טכניקות בינה מלאכותית ממלאות כיום תפקיד קריטי בשלבים שונים של הנדסת מערכות - החל מתכן קונספטואלי ועד לתחזוקה - ומאפשרות קבלת החלטות חכמה יותר, מחזורי איטרציה מהירים יותר וניהול טוב יותר של מורכבות וחוסר ודאות. אינטגרציה זו מעצבת מחדש את הכלים והפילוסופיות העומדות מאחורי הנדסת מערכות מודרנית [118-130]

1. ייצוג ידע והפעלת היגיון (Knowledge Representation and Reasoning - KRR)

טכניקת בינה מלאכותית בסיסית בהנדסת מערכות היא ייצוג ידע והיגיון, העוסקת בקידוד ידע בתחום לפורמטים שמכונות יכולות לפרש ולהיגיון איתם. מערכות KRR כמו אונטולוגיות²⁷, רשתות סמנטיות ומנועי לוגיקה מבוססי-כללים מאפשרות מידול פורמלי של דרישות מערכת, אילוצים וקשרים. לדוגמה, בהנדסת מערכות מבוססות מודלים (MBSE), אונטולוגיות משמשות ליצירת עקביות סמנטית בין מודלים ותחומים, מה שמאפשר שילוב טוב יותר של תת-מערכות הטרוגניות. מנועי חשיבה מבוססי בינה מלאכותית יכולים להסיק באופן אוטומטי סתירות, להציע שיפורי עיצוב ולדמות התנהגות מערכת בתנאים שונים.

2. למידת מכונה (ML)

למידת מכונה, תת-קבוצה של בינה מלאכותית המתמקדת ביכולת לאפשר למערכות ללמוד מנתונים, נמצאת בשימוש נרחב במידול ניבוי, זיהוי אנומליות, אופטימיזציה של מערכות וחיזוי התנהגות. בשלב התכן, אלגוריתמי למידה מפוקחים משתמשים בנתונים היסטוריים כדי לחזות כשלים ברכיבים, לייעל מדדי ביצועים או להעריך פשרות בין אפשרויות תכן מתחרות. בתפעול, מודלי למידה מפוקחת יכולים לנתח טלמטריה בזמן אמת כדי לזהות אנומליות במערכות מורכבות כמו מטוסים, לוויינים או תהליכים תעשייתיים.

טכניקות למידה לא מפוקחות, כגון אשכולות וצמצום ממדים, משמשות לגילוי תבניות ואבחון מערכות כאשר נתונים מתויגים אינם זמינים. למידת חיזוק (RL)²⁸, שבה סוכנים לומדים לקבל החלטות על ידי אינטראקציה עם הסביבה ומקסום אות תגמול, נמצאת בשימוש גובר בבקרת מערכות, רובוטיקה ותכן אדפטיבי. לדוגמה,

²⁷ An ontology is a formal representation of knowledge as a set of concepts within a specific domain and the relationships between them.

²⁸ Reinforcement learning (RL)

ניתן ליישם RL כדי לייעל ניתוב ברשתות תקשורת או להתאים פרמטרים תפעוליים בתגובה לתנאים חיצוניים משתנים.

3. עיבוד שפה טבעית (NLP)

הנדסת מערכות מודרנית כרוכה בכמויות עצומות של נתונים טקסטואליים: מפרטים, מסמכי דרישות, הצדקות עיצוב, יומני תחזוקה ומשוב מבעלי עניין. טכניקות עיבוד שפה טבעית (NLP) מאפשרות למהנדסים לחלץ תובנות, לזהות חוסר עקביות ולאטומטי את יצירת תיעוד המערכת. NLP יעיל במיוחד בהנדסת דרישות, שבה בינה מלאכותית יכולה לנתח מפרטי שפה טבעית ולהמיר אותם לייצוגים מובנים שניתן לנתח על מנת לבחון את שלמותם, עמימותם ועמידתם באילוצים.

התקדמות אחרונה במודלים של שפה גדולה (LLMs), כגון ChatGPT ו-BERT, מאפשרת הבנה סמנטית עמוקה יותר ואף הנמקה מודעת להקשר על פני מסמכים. יכולת זו תומכת בשיתוף פעולה בין בני אדם לבינה מלאכותית בקבלת החלטות, ניתוח תרחישים והערכת סיכונים.

4. מערכות מומחים ומנועים מבוססי-כללים (Expert Systems and Rule-Based Engines)

מערכות מומחים היו בין הצורות המוקדמות ביותר של בינה מלאכותית שאומצו בהנדסת מערכות. מערכות אלו מחקות מומחיות אנושית באמצעות כללי "אם-אז" והסקה לוגית. למרות שהן נחשבות ל"בינה מלאכותית קלאסית", מערכות מומחים נותרות רלוונטיות במערכות קריטיות למשימה כמו אוויוניקה (מכשור וציוד להתקנה במטוסים), שירותי בריאות והגנה, שבהן קבלת החלטות חייבת לדבוק בכללים ובתקנים מחמירים. בהנדסת מערכת (SE), מערכות מומחים משמשות לאבחון תקלות, ניהול תצורה ואימות תכן. בשילוב עם טכניקות בינה מלאכותית אחרות (למשל, לוגיקה עמומה), מערכות מבוססות-כללים יכולות גם להתמודד עם אי-ודאות ואמיתות חלקיות, מה שהופך אותן לגמישות יותר עבור יישומים בעולם האמיתי.

5. אלגוריתמים אבולוציוניים ומטה-יוריסטיות

(Evolutionary Algorithms and Metaheuristics)

בעיות אופטימיזציה הן מרכזיות בהנדסת מערכות, במיוחד בחקר מרחבי תכן, הקצאת משאבים וניתוח פשרות רבות יעדים. בינה מלאכותית מציעה כלים רבי עוצמה בתחום זה באמצעות אלגוריתמים אבולוציוניים (EAs) וטכניקות מטה-יוריסטיות²⁹, כגון אלגוריתמים גנטיים (GAs)³⁰, אופטימיזציית נחיל חלקיקים (PSO)³¹ ואופטימיזציית מושבת נמלים (ACO)³².

²⁹ Metaheuristic techniques are a class of problem-solving methods used to find optimal or near-optimal solutions to complex problems, especially those that are difficult to solve with traditional algorithms.

³⁰ genetic algorithms (GAs)

³¹ particle swarm optimization (PSO)

³² ant colony optimization (ACO)

טכניקות אלו אינן דורשות מידע גרדיאנט (gradient) אשר מתייחס לנתונים המתארים את קצב השינוי של פונקציה ביחס לנתוני כניסה שלה ויכולות לחקור מרחבי פתרונות גדולים, לא קמורים ולא רציפים ביעילות. לדוגמה, אלגוריתמים אבולוציוניים יכולים לפתח תצורות של ארכיטקטורות מערכת, לייעל פשרות עלות-ביצועים או ליצור לוחות זמנים אופטימליים לביצוע פרויקטים. גישות היברידיות המשלבות מטה-יוריסטיות עם למידת מכונה - כגון אופטימיזציה בסיוע פונדקאי - פופולריות יותר ויותר במערכות עם מודלי סימולציה יקרים.

6. תאומים דיגיטליים וסימולציה מונעת בינה מלאכותית

Digital Twins and AI-Driven Simulation

שילוב בינה מלאכותית עם תאומים דיגיטליים - העתקים וירטואליים של מערכות פיזיות - מייצג קפיצת מדרגה משמעותית בהנדסת ניבוי מערכות. בינה מלאכותית משפרת תאומים דיגיטליים על ידי מתן ניתוח נתונים בזמן אמת, תחזוקה נבויית ויכולות של קבלת החלטות אוטונומיות. לדוגמה, אלגוריתמי למידת מכונה משפרים ללא הרף את המודלים של התאום הדיגיטלי על סמך נתוני חיישנים, ומשפרים את דיוק הסימולציות והתחזיות.

תאומים דיגיטליים מונעי בינה מלאכותית אלה משמשים בתעופה וחלל, במערכי ייצור וערים חכמות כדי לדמות תרחישי "מה אם", לצפות כשלים במערכת ולהמליץ על פעולות מתקנות. בשילוב עם טכנולוגיות האינטרנט של הדברים (IoT), הם מציעים עדשה להסתכלות דינמית בזמן אמת על ביצועי המערכת וניהול מחזור החיים.

7. לוגיקה מטושטשת והנמקה הסתברותית

Fuzzy Logic and Probabilistic Reasoning

הנדסת מערכות עוסקת לעתים קרובות בחוסר ודאות, חוסר דיוק ומידע לא שלם. לוגיקה מטושטשת והנמקה הסתברותית הן טכניקות של בינה מלאכותית המאפשרות למהנדסים לקבל החלטות מושכלות בתנאים כאלה. לוגיקה מטושטשת משמשת למידול משתנים לשוניים והערכות סובייקטיביות (למשל, "סיכון גבוה" או "ביצועים בינוניים"), הנפוצים בשלבי תכן מוקדמים ובניתוח סיכונים.

רשתות בייסיאניות ותהליכי החלטה לפי שיטת מרקוב (MDPs)³³ מאפשרים מידול הסתברותי של אינטראקציות בין רכיבים ושרשראות כשל. כלים אלה בעלי ערך רב במיוחד בניתוח אמינות מערכות, תכן סבילות לתקלות ויישומים קריטיים לבטיחות כמו כלי רכב אוטונומיים או מערכות בקרה גרעיניות.

8. מערכות מרובות סוכנים (MAS) - Multi-Agent Systems (MAS)

ככל שמערכות הופכות מבוזרות ואוטונומיות יותר - כמו ברשתות חכמות, נחילי כטב"מים או ציי רכב אוטונומיים - מערכות מרובות סוכנים (MAS) מספקות מסגרת לתיאום מבוזר. סוכני בינה מלאכותית ב-MAS מקיימים אינטראקציה כדי להשיג מטרות קולקטיביות, להסתגל לשינויים סביבתיים ולפתור סכסוכים. הם

³³ Bayesian networks and Markov decision processes (MDPs)

יכולים ללמוד התנהגויות, לשתף מידע ולקבל החלטות מקומיות שמייעלות באופן קולקטיבי את הביצועים ברמת המערכת.

טכניקות MAS מיושמות בניהול רשתות, לוגיסטיקה, רובוטיקה שיתופית ומערכות סייבר-פיזיות. אתגרים מרכזיים כוללים משא ומתן בין סוכנים, פרוטוקולי תקשורת והבטחת התנהגויות מתפתחות גלובליות שיתאמו ליעדי המערכת - נושא של מחקר מתמשך בבינה מלאכותית.

9. בינה מלאכותית עבור מערכות של מערכות (SoS) ³⁴ - AI for Systems-of-Systems (SoS)

בהנדסת מערכות של מערכות, שבה מערכות עצמאיות וניתנות לפעולה הדדית משתפות פעולה כדי להשיג יכולות מקיפות, בינה מלאכותית ממלאת תפקיד מכריע באינטגרציה ובחיזוי התנהגות מתפתחת. המורכבות של אינטראקציות SoS דורשת טכניקות כגון אלגוריתמים בעלי יכולת הסתגלות עצמית, אופטימיזציה מבוזרת ומודלים של תורת המשחקים.

בינה מלאכותית מסייעת בניהול ומעקב אחר דינמיקת המערכת, פתרון תלות הדדית והבטחת ביצועים חזקים בהקשרים מבצעיים שונים. לדוגמה, במערכות הגנה לאומיות, בינה מלאכותית מסייעת במיזוג מידע בשדה הקרב בזמן אמת, תיאום מערכות נשק אוטונומיות ותכן אסטרטגי על פני תת-מערכות הטרוגניות.

10. מערכות תומכות החלטה (DSS) מועשרות ונתמכות על ידי בינה מלאכותית

AI-Augmented Decision Support Systems (DSS)

לאורך מחזור החיים של הנדסת מערכות, קבלת החלטות תחת אי ודאות היא פעילות מרכזית. מערכות תומכות החלטה (DSS) מועשרות על ידי בינה מלאכותית משלבות ניתוח נתונים, מודלים של סימולציה וחשיבה מבוססת בינה מלאכותית כדי לתמוך במהנדסים בניתוחי פשרות, סקירות תכן, ותכן מחזור חיים. מערכות אלו מציגות חלופות, מכמתות סיכונים ומדמות תוצאות על סמך מודלים המונעים על ידי בינה מלאכותית.

פלטפורמות DSS מודרניות משלבות ממשקים חזותיים ידידותיים למשתמש, אינטראקציה בשפה טבעית ושילוב עם כלי הנדסה דיגיטליים (למשל, מודלים של SysML) ³⁵, המאפשרים לבעלי עניין טכניים ולא טכניים כאחד להשתתף בתהליכי קבלת החלטות.

³⁴ A System of Systems (SoS) is a collection of independent, heterogeneous systems that are integrated to achieve a common, higher-level goal.

³⁵ The **systems modeling language (SysML)** is a general-purpose modeling language for systems engineering applications. It supports the specification, analysis, design, verification and validation of a broad range of systems and systems-of-systems. ([SOURCE](#))

סיכום

השילוב של בינה מלאכותית והנדסת מערכות אינה רק עניין של שיפור אוטומציה או כוח חישובי - היא משנה באופן מהותי את האופן שבו מערכות מורכבות נתפסות, מפותחות ומתפתחות. טכניקות בינה מלאכותית מביאות אינטליגנציה מסתגלת (אדפטיבית), זיהוי תבניות ויכולות למידה לתהליכים דטרמיניסטיים מסורתיים, ובכך מאפשרות מערכות חכמות ועמידות יותר. מניתוח דרישות מוקדם ועד לניהול מחזור חיים, בינה מלאכותית הופכת זרימות עבודה סטטיות לתהליכים דינמיים מונעי נתונים המסוגלים להגיב לחוסר ודאות, מורכבות ושינוי טכנולוגי מהיר.

ככל שהבינה המלאכותית ממשיכה להתקדם, מהנדסי מערכות חייבים לפתח שליטה רב-תחומית, המשלבת מומחיות בתחום עם הבנה של אלגוריתמים, מדעי נתונים ואינטראקציה בין אדם לבינה מלאכותית. מיזוג זה יעצב את הדור הבא של מערכות מהונדסות - המסוגלות לא רק לבצע משימות, אלא גם ללמוד, להסתגל ולמטב את פעולתן בסביבה משתנה ללא הרף.

במאמר [151] שכתרתו היא - עבודה בתהליך: הנדסה המונעת על ידי בינה מלאכותית - גישור בין תיאוריה ופרקטיקה אשר הוצג בכנס של IEEE בנושא חינוך מהנדסים, בוחן המאמר כיצד בינה מלאכותית יוצרת יכולה לסייע באוטומציה ובשיפור שלבים מרכזיים בהנדסת מערכות. הוא בוחן את יכולתה של בינה מלאכותית לנתח דרישות מערכת על סמך קריטריונים של "דרישה טובה" של INCOSE³⁶, תוך זיהוי דרישות מנוסחות היטב ודרישות שנכתבו בצורה גרועה. הבינה המלאכותית לא רק מסווגת דרישות אלא גם מסבירה מדוע חלקן אינן עומדות בתקנים. על ידי השוואת הערכות בינה מלאכותית לאלו של מהנדסים מנוסים, המחקר מעריך את הדיוק והאמינות של בינה מלאכותית בזיהוי בעיות איכות. בנוסף, הוא בוחן את יכולתה של בינה מלאכותית לסווג דרישות פונקציונליות ולא פונקציונליות וליצור מפרטי בדיקה על סמך סיווגים אלה. באמצעות ניתוח כמותי ואיכותני כאחד, המחקר שואף להעריך את הפוטנציאל של בינה מלאכותית לייעול תהליכי הנדסה ולשפר את תוצאות הלמידה. הוא גם מדגיש את האתגרים והמגבלות של בינה מלאכותית, תוך הבטחת השימוש הבטוח והאתי בה במסגרות מקצועיות ואקדמיות.

³⁶ INCOSE: The Trusted Authority in Systems Engineering. <https://www.incose.org/>

6. טכניקות של בינה מלאכותית בהנדסה

6.1. מיפוי שיטות מבוססות בינה מלאכותית לשלבי תכן הנדסי

תכן הנדסי הוכח כהקשר עשיר ליישום שיטות בינה מלאכותית (AI), אך נראה כי חסר סיווג של שיטות כאלה המיושמות במחקרי תכן מבוססי בינה מלאכותית. מאמר של Khanolkar ושותפים מציג סקירת ספרות ממוקדת של שיטות מבוססות בינה מלאכותית הממופות לשלבים השונים של תהליך התכן ההנדסי ומתאר כיצד שיטות אלו מסייעות לתהליך התכן. המחברים בסקר ספרות זה [6] סקרו 108 מאמרים על תכן הנדסי מבוססי בינה מלאכותית מכתבי עת שעברו ביקורת עמיתים ודיוני כנסים ומיפו את תרומתם לחמישה שלבים של תהליך התכן ההנדסי. סיווגנו שבע שיטות מבוססות בינה מלאכותית במערך הנתונים שהם יצרו. מחקר ספרותי זה הצביע על כך שרוב עבודות המחקר על תכן מבוסס בינה מלאכותית מכוונות לשלבי התכן הקונספטואלי והראשוני. המחברים משערים כי סביר להניח שזו תוצאה של מספר גורמים, כולל האופי האיטרטיבי של משימות התכן בשלבים אלה, זמינותם של מאגרי נתוני תכן פתוחים והנטייה להשתמש בבינה מלאכותית לעיבוד משימות עתירות חישוב, כמו אלו בשלבים אלה. המחקר שלהם הצביע גם על כך ששיטות אלו תומכות במתכננים על ידי סינתזה ו/או ניתוח של נתוני תכן, מושגים ומודלים בשלבי התכן. סקירת ספרות זו שואפת לספק לקוראים מיפוי אינפורמטיבי של כלי בינה מלאכותית שונים לשלבי תכן הנדסי, ולעודד מהנדסים, חוקרי תכן וסטודנטים להבין את המצב הנוכחי ולזהות הזדמנויות ליישום יישומי בינה מלאכותית בתכן הנדסי.

באמצעות סקירת הספרות החוקרים עסקו בשאלות המחקר המרכזיות הבאות:

- **RQ-1:** Which AI-based methods are commonly applied in each engineering design stage?
- **RQ-2:** Why are AI-based methods prevalent in certain engineering design stages?
- **RQ-3:** How do AI-based methods support designers in each engineering design stage?

על ידי התייחסות ליעדים אלה, הסיווג השלבי של ספרות בנושא התכן מבוסס בינה מלאכותית מציע תובנות בנוגע לאופי השיטות מבוססות הבינה המלאכותית המתמקדות בשלבים ספציפיים של תהליך התכן ההנדסי, ומדוע חוקרים התמקדו ביישום שיטות בינה מלאכותית מסוימות בשלבים ספציפיים אלה. בפועל המחקר מדגיש שבע שיטות מבוססות בינה מלאכותית, שהן **מידול מבוסס סוכנים, למידה עמוקה, למידת מכונה, עיבוד שפה טבעית (NLP), תורת הרשתות, מידול הסתברותי, ואלגוריתמים של אופטימיזציה**. שבע שיטות אלה ממופות לשלבי התכן ההנדסי ומתארות אילו שיטות מבוססות בינה מלאכותית נפוצות בכל שלב של התכן ההנדסי. הבנה של התפלגות עבודות המחקר מבוססות בינה מלאכותית עשויה להאיר הזדמנויות בעלות ערך גבוה עבור חוקרי תכן לחקור האם שיטות מבוססות בינה מלאכותית יכולות לתמוך במשימות התכן בשלבים הפחות מנוצלים.

תהליך התכן ההנדסי

תהליך התכן ההנדסי דורש שילוב של ידע ומיומנויות של בני אדם, כולל מומחיות בסיסית בנושאים מדעיים (בפיזיקה, כימיה, חישוב, אופטימיזציה וכו') וניסיון הנדסי מעשי כמו גם פתרון בעיות ויצירתיות. התפקיד שממלאים בני אדם בתהליך זה היה מוקד למחקר משמעותי, בפרט בכל הנוגע לנושאים כמו יצירתיות, אמפתיה, אינטואיציה, ניסיון ושיתוף פעולה. תכן הנדסי הוא תהליך מורכב וכולל שלבים מרובים, שכל אחד מהם מכיל מגוון משימות ייחודיות המקדמות את התכן לעבר מערכת מושלמת. משימות אלו דורשות מיומנויות וידע מיוחדים שנרכשו באמצעות שנים של לימוד או עבודה - ולעתים קרובות חורגות מניסיונו של מתכנן יחיד. לבסוף, תהליך התכן הוא לעתים רחוקות ליניארי: תכן עשוי לעבור דרך מספר שלבים אלה לפני שיתקדם. מתוך הכרה במורכבות זו, החוקרים סיכמו תהליך זה לחמישה שלבים המתאימים לניתוח הספרות שבוצע בנושא. להלן סקירת חמשת השלבים הללו כדלקמן:

1. **הגדרת בעיה:** מטרת התכן, האילוצים, הפונקציות ומידע אחר מזוהים בשלב הגדרת הבעיה כדי ליצור רשימה של דרישות הלקוח, הלקוח או משתמש הקצה. מתכננים מסתמכים על אמפתיה כדי להבין את דרישות הלקוח, ביקורות מוצרים קיימות ותגובות, מה שעוזר למהנדס המתכנן לתרגם אותן לפרמטרים ודרישות תכן ועיצוב. בדרך זו, רשימה מפורטת ומדויקת של דרישות, הצהרות, יעדים, אילוצים ופונקציות שהתקבלו בשלב זה משמשות כקלט לשלב התכן הקונספטואלי הבא.

2. **תכן קונספטואלי:** בשלב זה, הדרישות שהתקבלו מהשלב הקודם מתורגמות למפרטי תכן הנדסי המשמשים להשוואת ביצועים של תכנונים ועיצובים פוטנציאליים. מעצבים רותמים את היצירתיות והאינטואיציה שלהם שנצברו מניסיונם בשלב התכן הקונספטואלי כדי לסייע בתהליך הרעיון וליצור חלופות עיצוב חדשות. באמצעות תהליך רעיון זה, נוצרות חלופות תכן מרובות בהתאם למפרטי התכן ההנדסי העונים כראוי על דרישות הלקוח, יעדיו, אילוציו ומכלול הפונקציות הרצויות. מושגי תכן מרובים אלה משמשים כקלט לשלב התכן הבא לצורך מידול, הערכה וניתוח.

3. **תכן ראשוני:** בשלב זה, מושגי התכן החלופיים מעוצבים על ידי הערכת גודל והיקף דרישות התכן והמאפיינים העיקריים שלהן. מהנדסים משתמשים בתוכנת תכן בעזרת מחשב (CAD)³⁷ למידול מושגי התכן לצורך ויזואליזציה יעילה. באמצעות תכונות הדמיה מבוססות CAD, מהנדסים יכולים לרתום את היצירתיות שלהם ליצירת מודלי תכן. מודלים אלה נבדקים ומוערכים על סמך דרישות הביצועים והתפקוד של הלקוח. תהליך זה ממנף בעיקר כלי חישוב כגון CAD ותוכנות סימולציה לניתוח מהיר ויעיל של מושגי התכן. לאחר הניתוח, המהנדסים משתמשים בכישורי קבלת ההחלטות שלהם כדי לבחור את התכנונים והעיצובים המתאימים לדרישות.

4. **תכן מפורט:** בשלב זה, מההערכות בשלב הקודם, התכן הנבחר מנוסח בצורה מפורטת. כדי לייעל את התכן, המהנדסים המתכננים משתמשים בהליכים המובעים בכללים, נוסחאות ואלגוריתמים ספציפיים המצויים בקודי תכן, ספרי הדרכה, מסדי נתונים וקטלוגים. באמצעות כישורי ושיטות קבלת ההחלטות שלהם, המתכננים והמעצבים מסיימים תכן ועיצוב מתאים עם פרטים רלוונטיים שיועברו בשלב הבא.

³⁷ computer-aided design (CAD)

5. **תקשורת עיצובית:** בשלב הסופי הזה של תהליך התכן ההנדסי, התכן הסופי על פרטיו מתועד ומועבר בצורה של דוחות, שרטוטים, מפרטי ייצור ואבות טיפוס. מהנדסים מתכננים ממנפים את החשיבה היצירתית שלהם כדי לתכנן, לעצב ולבנות אבות טיפוס ומסתמכים על אמפתיה כדי להעביר ביעילות את האבות טיפוס והעיצובים הסופיים ללקוחות ובעלי עניין. כל תהליך התכן מתועד גם הוא, שכן הדבר עשוי להיות מועיל לעיון עתידי. תהליך התקשורת העיצובית יכול גם לסייע בקבלת משוב מלקוחות ובעלי עניין כדי לשנות את התכן עוד יותר ולספק את אישורם הסופי.

אלגוריתמים של בינה מלאכותית ותהליך התכן

בעוד שמטרת עבודת התכן ההנדסי נותרת קבועה לאורך זמן, אופי עבודת ההנדסה משתנה, בין היתר עקב הזמינות הגוברת של נתונים ואלגוריתמים שונים של בינה מלאכותית. למידת מכונה, למידה עמוקה ועיבוד שפה טבעית (NLP) הן חלק מהשיטות הנפוצות ביותר המבוססות על בינה מלאכותית לעיבוד ופירוש של מגוון רחב של סוגי נתונים, כולל יישומים החל מהמלצות מוצרים, ראיית מכונה ותרגום שפות, בהתאמה. למידת מכונה קלאסית היא הכלי הנפוץ ביותר לעיבוד נתונים בקנה מידה גדול ולמידת תכונות ודפוסים בנתונים באמצעות ניתוח סטטיסטי. אלגוריתמים קלאסיים של למידת מכונה כגון עצי החלטה, טכנולוגיית Naive-Bayes³⁸, מכונות וקטור תמיכה, K שכנים קרובים³⁹ ושיטות רגרסיה היו שימושיות לסיווג, חיזוי ואישיכול נתונים ביעילות. למידה עמוקה, תת-קבוצה של אלגוריתמי למידת מכונה, ממנפת רשתות עצביות מלאכותיות כדי לעבד, לפרש ואף לייצר נתונים המתבטאים בתמונות, מודלים תלת-ממדיים וסרטונים. בהשוואה לאלגוריתמי למידת מכונה קלאסיים, אלגוריתמי למידה עמוקה דורשים פחות התערבויות אנושיות ויכולים ללמוד ולחלץ אוטומטית תכונות מנתונים בקנה מידה גדול, ולספק תוצאות בדיוק גבוה ולכן מתאימים לעיבוד נתונים מורכב כגון ראיית מכונה, עיבוד אודיו ומודלים גנרטיביים. NLP כולל נתונים מבוססי טקסט, ומגשר על הפער בין שפת "מחשב" לשפה "אנושית" באמצעות ייצוג ידע כדי לגשת, לאחסן ולנתח מידע המבוסס בשפה טבעית. שיטת NLP היא בשימוש עם למידת מכונה או אלגוריתמים של למידה עמוקה עבור יישומים כגון צ'אטבוטים, ניתוח סנטימנטים, תיקון אוטומטי ותרגום מכונה.

למרות ששלוש שיטות אלו⁴⁰ נמצאות בשימוש נרחב, שיטות אחרות מבוססות בינה מלאכותית, כגון מידול מבוסס סוכנים, תורת הרשתות/גרפים, שיטות הסתברותיות ואלגוריתמי אופטימיזציה, נמצאות גם הן בשימוש עבור משימות הכרוכות בעיבוד נתונים, אוטומציה ואופטימיזציה. מידול מבוסס סוכנים כרוך בפיתוח של סוכן או סוכנים חישוביים יחד עם סביבה שבה הסוכן או סוכנים מרובים מקיימים אינטראקציה עם הסביבה כדי להשיג תוצאות מסוימות. תורת הרשתות/גרפים כוללת חקר אינטראקציות או יחסים בין אובייקטים בדידים המיוצגים בצורת גרפים. שיטות הסתברותיות, הכוללות מודלים כמו מודל נסתר מרקוב (Hidden Markov models), מסגרות בייסיאניות (Bayesian frameworks) ובנוסף מודלים גאוסיאניים (Gaussian models), משמשות להערכת הסבירות של אירועים/מצבים על סמך תורת ההסתברות ומידול סטטיסטי של

³⁸ Naive Bayes is a classification algorithm that uses Bayes' Theorem with the assumption of independence between features

³⁹ K-Nearest Neighbors (KNN) is a supervised machine learning algorithm used for both classification and regression tasks.

⁴⁰ למידת מכונה, למידה עמוקה ועיבוד שפה טבעית (NLP)

נתונים זמינים. אלגוריתמי אופטימיזציה, כגון אלגוריתם גנטי, אופטימיזציה בייסיאנית ואופטימיזציה של טופולוגיה רב-ממדית, משמשים להשגת הפתרון הטוב ביותר באופן איטרטיבי במסגרת אילוצים נתונים.

מאז ההופעה של **Industry 4.0**, תעשיות רבות החלו לשלב כלי בינה מלאכותית כדי לזרז את עיבוד הנתונים וקבלת ההחלטות עבור משימות מורכבות. עם המעבר לכלים דיגיטליים, חיישנים ונתוני ביג דאטה הנגישים דרך מערכות סייבר-פיזיות, כמויות עצומות של ידע עיצובי, עיצובי מוצרים קודמים, ביקורות של לקוחות ויכולות ייצור זמינות כדי לסייע למהנדסי עיצוב להאיץ את תהליך עיצוב המוצר. הזמינות של נתוני עיצוב עשירים ומגוונים במאגרים פתוחים הובילה להופעת ספרות המשקפת יישומי בינה מלאכותית חדשים בכל שלב בתהליך התכן ההנדסי. ככזה, מחקר ספרותי המדגיש מתודולוגיות שונות של בינה מלאכותית הממופות לחמשת שלבי התכן ההנדסי יכול להניע חוקרים, מהנדסים ושופטים להנדסה לזהות את הפוטנציאל של שימוש בשיטות מבוססות בינה מלאכותית. יתר על כן, מוטיבציה כזו יכולה לעורר עוד יותר את הפיתוח של מתודולוגיות חדשות לסינתזה או ניתוח עיצובים בשלבים השונים של תהליך התכן ההנדסי.

בסקירת המאמרים, מתברר שנעשה שימוש בעיקר בשבע שיטות מבוססות בינה מלאכותית המשמשות לעיבוד משימות תכן עיצוב בהנדסה. להלן מפורטים כל שבע השיטות הללו המבוססות על בינה מלאכותית כדלקמן:

מיפוי הספרות לשלבי התכן ההנדסי

בעקרון קיימות 7 שיטות שונות בתהליך התכן ההנדסי והן:

1. Agent-based modeling
2. Deep learning
3. Machine learning
4. Network/graph theory
5. NLP
6. Optimization algorithms
7. Probabilistic methods

מן הראוי להדגיש שלאינטליגנציה יש הקשר רחב יותר המשקף יכולת עמוקה יותר להבין את הסביבה. עם זאת, כדי שהיא תחשב כבינה מלאכותית, כל מרכיביה צריכים לעבוד יחד. לכן חשוב מאוד שנבין את המרכיבים המרכזיים של בינה מלאכותית.

להלן תיאור שימוש בבינה מלאכותית בהגדרת בעיות, בעיצוב רעיוני (קונספטואלי), בתכן ראשוני, בתכן מפורט, ובתהליך תקשורת עיצובית המשמשת להעברת התכן לשלבי ביצוע.

שימוש בבינה מלאכותית בהגדרת דרישות בתכן הנדסי

הגדרת דרישות היא שלב יסודי בתכן הנדסי, המשמש כמצפן המנחה את כל תהליכי הפיתוח הבאים. באופן מסורתי, הגדרת דרישות הנדסיות הסתמכה במידה רבה על ידע מומחה, ניסיון ספציפי לתחום והתייעצויות איטרטיביות (מחזוריות) עם בעלי עניין. עם הופעתה של הבינה המלאכותית (AI), שלב קריטי זה עובר טרנספורמציה. בינה מלאכותית משפרת את תהליך הגדרת הדרישות בכך שהיא מאפשרת למהנדסים לנתח מערכי נתונים עצומים ומורכבים, לזהות דפוסים נסתרים וליצור תובנות שעלולות להתעלם מהן בשיטות קונבנציונליות.

יישום מרכזי אחד של בינה מלאכותית בהגדרת דרישות הוא באמצעות **עיבוד שפה טבעית** (NLP). מערכות בינה מלאכותית המצוידות ביכולות NLP יכולות לנתח משוּב לקוחות, תיעוד טכני, פטנטים וספרות מדעית כדי לחלץ באופן אוטומטי בעיות חוזרות, פערים בביצועים וצרכי משתמשים. זה עוזר למהנדסים לנסח הצהרות דרישות מדויקות ומקיפות יותר. לדוגמה, מודל בינה מלאכותית שאומן על סקירות מוצרים יכול לזהות מצבי כשל נפוצים או תסכולים של משתמשים, מה שמאפשר לצוות התכן להגדיר דרישה בצורה מדויקת יותר סביב מקרי שימוש בעולם האמיתי.

למידת מכונה, ובמיוחד טכניקות למידה לא מפוקחות כגון אשכולות וצמצום מימדיות, יכולה גם לתמוך בזיהוי דפוסים בתוך נתוני חיישנים, יומני תחזוקה או תוצאות סימולציה. על ידי הדגשת אנומליות או התנהגויות חוזרות, כלי בינה מלאכותית אלה עוזרים למהנדסים להבין את הגורמים הבסיסיים לצווארי בקבוק בביצועים או בעיות אמינות, מה שמוביל להגדרת דרישות מושכלות וממוקדות יותר.

גישה מתפתחת נוספת כרוכה ב**שימוש במערכות ידע לתכן הנדסי מבוססות בינה מלאכותית הלומדות מפרויקטים הנדסיים קודמים**. מערכות אלה ממנפות הנמקה מבוססת מקרה או ידע גרפי כדי להציע אילוצים פוטנציאליים, מדדי ביצועים או דרישות בעלי עניין שאולי לא נלקחו בחשבון בתחילה. על ידי שילוב ידע היסטורי והקשרי, בינה מלאכותית יכולה להפחית את הסיכונים של פיקוח בשלבים המוקדמים של התכן.

חשוב לציין, בינה מלאכותית אינה מחליפה את המהנדס האנושי בהגדרת הבעיה, אלא משפרת את קבלת ההחלטות עם תובנות מונחות נתונים. מהנדסים עדיין ממלאים תפקיד מכריע בפירוש פלטי בינה מלאכותית, אימות הנחות והתאמת דרישות ליעדים אסטרטגיים ושיקולים אתיים. ככל שכלי בינה מלאכותית הופכים אינטראקטיביים יותר וניתנים להסבר, הם משמשים יותר ויותר כמשתפי פעולה חכמים - משפרים את היצירתיות, מפחיתים עמימות ומשפרים את היעילות והאיכות של תכן הנדסי כבר מהצעד הראשון.

לסיכום, שילוב הבינה המלאכותית בהגדרת דרישות בתכן הנדסי מייצג שינוי לעבר חדשנות מושכלת יותר, מגיבה וממוקדת משתמש. על ידי ניצול יכולתה של הבינה המלאכותית לעבד מידע בקנה מידה גדול ולחשוף קשרים לא ברורים מאליהם, מהנדסים יכולים להגדיר אתגרי תכן בצורה מדויקת ומקיפה יותר - ובכך להכין את הבמה לפתרונות שאינם רק מבוססים מבחינה טכנית אלא גם תואמים לצרכים של העולם האמיתי.

שימוש בבינה מלאכותית בשלב התכן הקונספטואלי של תכן הנדסי

שלב התכן הקונספטואלי או הרעיוני בהנדסה הוא המקום שבו רעיונות מופשטים הופכים למודלים ראשוניים ופתרונות פונקציונליים. זהו שלב יצירתי קריטי הכולל חקירה של חלופות מרובות, חשיבה ברמת המערכת והגדרת ארכיטקטורה ברמה גבוהה. באופן מסורתי, תהליך זה תלוי ביצירתיות, בניסיון ובאינטואיציה של מהנדסים. עם זאת, בינה מלאכותית (AI) הופכת יותר ויותר לכלי רב עוצמה להרחבת שלב זה, ומאפשרת תפיסה מהירה, רחבה וחדשנית יותר.

אחת הדרכים המשפיעות ביותר בהן בינה מלאכותית תורמת לתכן קונספטואלי היא באמצעות תכן

גנרטיבי. באמצעות אלגוריתמים בהשראת תהליכים אבולוציוניים, בינה מלאכותית יכולה לייצר באופן אוטונומי אלפי חלופות עיצוב על סמך מטרות, אילוצים ופרמטרים מוגדרים כגון שימוש בחומרים, עלות, חוזק מבני ויכולת ייצור. לאחר מכן מהנדסים יכולים להעריך ולשפר את הקונספטים המבטיחים ביותר, להרחיב משמעותית את מרחב התכן ולהפחית את הזמן המושקע בחקירה של ניסוי וטעייה. כלי תכן גנרטיביים המופעלים על ידי בינה מלאכותית נמצאים בשימוש נרחב בתחומים כמו תעופה וחלל, רכב ואדריכלות כדי ליעל את המשקל, הביצועים והיעילות כבר מהשלבים המוקדמים ביותר.

אלגוריתמים של למידת מכונה מסייעים גם למהנדסים בזיהוי תצורות קונספטואליות אופטימליות על ידי ניתוח נתוני תכן היסטוריים, תוצאות סימולציה ומדדי ביצועים. מערכות בינה מלאכותית אלו יכולות לזהות דפוסים וקשרים המנחים את בחירת אסטרטגיות תכן יעילות, ועוזרות למהנדסים להימנע ממלכודות שנתקלו בהן בעבר ולבנות על קונספטים מוצלחים. בנוסף, מערכות המלצות תכן מבוססות בינה מלאכותית יכולות לספק למהנדסים הצעות לרכיבים, תת-מערכות או פריסות אדריכליות שנלקחו ממסדי נתונים של מוצרים או סטנדרטים קיימים.

כלי סימולציה ומידול מונעי בינה מלאכותית מאפשרים הערכה מהירה של חלופות קונספטואליות בתנאי הפעלה שונים. על ידי שילוב משוב בזמן אמת ותחזיות ביצועים, מהנדסים יכולים לחזור על קונספטים בצורה יעילה יותר ולאמת היתכנות מוקדם יותר בתהליך. יתר על כן, בינה מלאכותית יכולה להקל על תכן שיתופי על ידי תרגום תיאורים בשפה טבעית או סקיצות ידניות למודלים דיגיטליים ראשוניים, מה שמאפשר לצוותים רב-תחומיים לתקשר רעיונות בצורה יעילה יותר.

חשוב לציין, השימוש בבינה מלאכותית בתכן קונספטואלי אינו מבטל את הצורך ביצירתיות אנושית ובשיקול דעת הנדסי. במקום זאת, בינה מלאכותית פועלת כיוצרת משותפת - משפרת את תהליך הרעיונות, חושפת פתרונות לא ברורים מאליהם ועוזרת לצוותים לנווט במורכבות של אתגרי תכן מודרניים. התוצאה היא גישה חזקה, זריזה וחדשנית יותר לתכן הנדסי בשלבים מוקדמים.

לסיכום, בינה מלאכותית מעצימה מהנדסים בשלב התכן הקונספטואלי על ידי הרחבת אפשרויות יצירתיות, האצת חקירה ושיפור קבלת ההחלטות. ככל שכלי בינה מלאכותית הופכים אינטואיטיביים יותר ומשולבים עמוק בזרימות עבודה של תכן, תפקידם בעיצוב הדור הבא של מערכות מהונדסות ימשיך לגדול - ויאפשר חדשנות חכמה יותר, קיימא יותר וממוקדת יותר במשתמש.

שימוש בבינה מלאכותית בשלב התכן המקדים של תכן הנדסי

שלב התכן המקדים בתכן הנדסי הוא שלב קריטי שבו נבנה הבסיס של מוצר או מערכת, ומתרגמים רעיונות קונספטואליים לחלופות עיצוב ישימות. בצומת זה, מהנדסים מגדירים פרמטרים מרכזיים, מנתחים פשרות ומתחילים לעצב את ארכיטקטורת המערכת. השימוש בבינה מלאכותית (AI) בשלב זה הפך ליקר ערך יותר ויותר, ומשפר משמעותית הן את היעילות והן את איכות קבלת ההחלטות. כלי בינה מלאכותית, במיוחד אלו המופעלים על ידי למידת מכונה (ML), עיבוד שפה טבעית (NLP) ואלגוריתמים גנרטיביים, מסייעים באוטומציה של ניתוחים מורכבים, אופטימיזציה של תצורות וזיהוי פתרונות חדשניים המבוססים על כמויות עצומות של נתונים היסטוריים ובזמן אמת.

אחת התרומות העיקריות של בינה מלאכותית בשלב התכן המקדים היא יצירה והערכה מהירים של חלופות עיצוב מרובות. אלגוריתמי תכן גנרטיביים משתמשים בבינה מלאכותית כדי לחקור אלפי - או אפילו מיליונים - של תצורות עיצוב פוטנציאליות על ידי הגדרת יעדי עיצוב ואילוצים. לדוגמה, בהנדסת מבנים או תכן חלל, מהנדסים יכולים להזין דרישות ביצועים, תכונות חומר ומגבלות מרחביות, ומערכות בינה מלאכותית יציעו תצורות יעילות מבחינה מבנית וניתנות לייצור. יכולת חקירה זו לא רק מאיצה את תהליך התכן, אלא גם חושפת פתרונות חדשים שעשויים שלא להתפתח בשיטות מסורתיות.

בינה מלאכותית מאפשרת גם קבלת החלטות מושכלת יותר באמצעות מודלים ניבויים וסימולציות מונחות נתונים. במקום להסתמך אך ורק על חישובים ידניים או ניתוחי אלמנטים סופיים עתירי זמן, מהנדסים יכולים למנף את הבינה המלאכותית כדי לבנות מודלים חלופיים - מודלים סטטיסטיים שאומנו לקרב התנהגויות פיזיות. מודלים אלה יכולים להעריך במהירות שינויים בתכן ולחזות תגובות מערכת כגון התפלגות מאמצים, יעילות תרמית או צריכת אנרגיה. בכך, הבינה המלאכותית מפחיתה את הזמן והמשאבים הנדרשים לאימות והערכת סיכונים בשלב מוקדם.

יתר על כן, בינה מלאכותית משפרת את האינטגרציה הרב-תחומית, סימן היכר של תכן הנדסי מודרני. אלגוריתמי NLP יכולים לחלץ ולהרמוניזציה של מידע ממקורות תיעוד מגוונים - סטנדרטים, דוחות פרויקטים קודמים, ספרות מדעית - התומכים בבדיקות תכן וציות מונחות ידע. מערכות בינה מלאכותית יכולות גם להקל על שיתוף פעולה בין צוותים חוצי-תפקודים על ידי הבטחת עקביות תכן ושילוב תשומות מנקודות מבט חשמליות, מכניות, תוכנה והנדסת מערכות.

לסיכום, בינה מלאכותית משנה את שלב התכן המקדים על ידי אוטומציה של חקירה, שיפור דיוק החיזוי, שיפור שיתוף הפעולה והאצת זיהוי הפתרונות האופטימליים. על ידי שילוב כלי בינה מלאכותית בשלב מוקדם של תהליך התכן, מהנדסים יכולים להתאים טוב יותר את העיצובים לדרישות פונקציונליות, ציפיות הלקוחות ויעדי הקיימות, ובכך להניח בסיס איתן לפיתוח הנדסי וחדשנות במהלך התכן הנדסי.

שימוש בבינה מלאכותית בשלב התכן המפורט של תכן הנדסי

שלב התכן המפורט בתכן הנדסי הוא המקום שבו מושגים מופשטים ורעיונות ראשוניים מתפתחים לתוכניות מדויקות וניתנות לפעולה, מוכנות לייצור ויישום. שלב זה כולל יצירת שרטוטים מפורטים, מפרטים, גיאומטריות של חלקים, בחירת חומרים, הגדרות סבילות ושילוב עם תהליכי ייצור. בינה מלאכותית (AI) ממלאת תפקיד טרנספורמטיבי יותר ויותר בשלב זה על ידי אוטומציה של משימות מורכבות, שיפור הדיוק, מזעור טעויות אנוש ומאפשר אופטימיזציה המבוססת על נתונים בזמן אמת ואילוצי תכן.

אחד היישומים החזקים ביותר של בינה מלאכותית בשלב התכן המפורט הוא אוטומציה של תכן. כלי CAD (תכן בעזרת מחשב) המונעים על ידי בינה מלאכותית יכולים ליצור מודלים דו-ממדיים ותלת-ממדיים מפורטים המבוססים על פרמטרי קלט, אילוצים ונהלים סטנדרטיים. כלים אלה משתמשים בהיגיון מבוסס כללים ובאלגוריתמים גנרטיביים כדי להפוך משימות חוזרות ונשנות לאוטומטיות כגון פריסת רכיבים, תכונות מימדים או מידול של הרכבה. לדוגמה, בהנדסת מכונות, בינה מלאכותית יכולה לייצר באופן אוטומטי פרופילים מפורטים של גלגלי שיניים, סנפירי קירור או תומכים המותאמים לדרישות עומס ספציפיות, ובכך להאיץ משמעותית את ציר הזמן של התכן.

בינה מלאכותית גם מאפשרת ניתוחי תכן לייצור (DFM)⁴¹ ותכן להרכבה (DFA)⁴² בשלב התכן המפורט. מערכות בינה מלאכותית יכולות לנתח מודלים מפורטים של CAD כדי לזהות מאפיינים שעלולים לגרום לאתגרים בייצור - כגון חיתוכים, הקפדה על מידות הדוקות או גיאומטריות קשות לעיבוד - ולהציע שינויים. מודלים של למידת מכונה שאומנו על נתוני ייצור היסטוריים יכולים לחזות פגמי ייצור, להציע החלפות חומרים או להמליץ על טכניקות עיבוד חלופיות, ובכך להפחית איטרציות של אב טיפוס ועלויות נלוות.

יתר על כן, ניתוח סבילות (טולרנטיות) וסימולציה הם קריטיים בשלב התכן המפורט. כלי ניתוח סבילות המונעים על ידי בינה מלאכותית משתמשים במודלים הסתברותיים כדי להעריך כיצד שינויים בממדים ובהרכבה משפיעים על ביצועי המוצר. במקום סימולציות ממצות, מהנדסים יכולים להשתמש במודלים חלופיים מבוססי בינה מלאכותית כדי לחזות התנהגות תרמית, נוזלית, מבנית או אלקטרומגנטית תחת מקרי עומס מרובים - ולשפר את חוסן התכן מבלי לצרוך משאבי חישוב מוגזמים.

בינה מלאכותית גם משפרת זרימות עבודה שיתופיות וניהול גרסאות תכן. כלי עיבוד שפה טבעית (NLP) יכולים לסייע בפירוש שינויים ותיעוד תכן, בעוד שמערכות בקרת גרסאות המונעות על ידי בינה מלאכותית יכולות לסמן חוסר עקביות, לעקוב אחר תיקונים ולשמור על עמידה בתקני הנדסה. שילוב עם מערכות ניהול מחזור חיי מוצר (PLM)⁴³ מבטיחה זרימת נתונים חלקה בין צוותי הנדסה, איכות וייצור.

לסיכום, בינה מלאכותית משפרת את שלב התכן המפורט על ידי הפחתת עבודה ידנית, שיפור הדיוק, אופטימיזציה של יכולת ייצור וביצועים וייעול שיתוף הפעולה. על ידי הטמעת בינה מלאכותית בזרימות עבודה של תכן מפורט, מהנדסים יכולים לספק מוצרים באיכות גבוהה יותר מהר, עם פחות שגיאות ועלויות נמוכות יותר, ובסופו של דבר להניע חדשנות ותחרותיות בשיטות הנדסיות מודרניות.

שימוש בינה מלאכותית בשלב התקשורת התכנונית של תכן הנדסי

שלב התקשורת התכנונית בתכן הנדסי חיוני לתרגום מידע טכני מורכב לפורמטים ברורים וניתנים לפעולה עבור בעלי עניין שונים - מהנדסים, יצרנים, לקוחות והנהלה. שלב זה כרוך ביצירת תיעוד מפורט, כולל דוחות תכן, מפרטי ייצור, שרטוטים טכניים, מצגות, ולעתים קרובות, אבות טיפוס פיזיים או וירטואליים. בינה

⁴¹ design for manufacturability (DFM)

⁴² design for assembly (DFA)

⁴³ Product Lifecycle Management (PLM)

מלאכותית (AI) משפרת משמעותית את האפקטיביות והיעילות של שלב זה על ידי ייעול התיעוד, אוטומציה של ויזואליזציה ושיפור מעורבות בעלי העניין באמצעות יצירת תוכן ופרשנות חכמים.

תרומה עיקרית אחת של בינה מלאכותית לתקשורת תכנונית היא אוטומציה של תיעוד טכני. כלי עיבוד שפה טבעית (NLP) יכולים לנתח מודלים הנדסיים, מפרטים ונתוני תכן כדי ליצור באופן אוטומטי דוחות תכן מקיפים, כתבי חומרים (BOMs)⁴⁴ ורשימות תיוג תאימות. מערכות בינה מלאכותית אלו מבטיחות עקביות בשפה ובעיצוב, מפחיתות טעויות אנוש וחוסכות זמן ניכר בהכנת תיעוד מורכב. יתר על כן, מודלים של NLP רב-לשוניים יכולים לתרגם תוכן טכני לשפות שונות, ולשפר את הנגישות עבור צוותים ולקוחות גלובליים.

כלים המופעלים על ידי בינה מלאכותית משפרים גם את התקשורת החזותית של עיצובים. אלגוריתמים של למידת מכונה יכולים לייצר הדמיות, סימולציות ואנימציות באיכות גבוהה ישירות ממודלים של CAD, ובכך לסייע לבעלי עניין שאינם טכניים להבין טוב יותר את כוונת התכן ההנדסי והעיצוב. לדוגמה, בינה מלאכותית יכולה ליצור הדמיות אמיתיות של איך מוצר ייראה ויתפקד בסביבות שונות או בתנאים שונים, ובכך לסייע בקבלת החלטות של בעלי עניין ובמצגות שיווקיות. כלים אלה שימושיים במיוחד להעברת היבטי עיצוב שקשה ללכוד באמצעות שרטוטים סטטיים או טקסט בלבד.

במונחים של אבות טיפוס, בינה מלאכותית משתלבת עם פלטפורמות תאומים דיגיטליים ומציאות רבודה/מדומה (AR/VR)⁴⁵ כדי ליצור אבות טיפוס וירטואליים אינטראקטיביים. סימולציות אלו, המשופרות על ידי בינה מלאכותית, מאפשרות לבעלי עניין לבדוק ולקיים אינטראקציה עם העיצוב בסביבה וירטואלית, ומאפשרות משוב מוקדם ללא העלות והזמן של אבות טיפוס פיזיים. יתר על כן, בינה מלאכותית יכולה לנתח אינטראקציות של משתמשים עם אבות טיפוס דיגיטליים אלה כדי לזהות בעיות שימושיות או פגמים בעיצוב, ולספק הצעות מבוססות נתונים לעידון התכן.

בינה מלאכותית תומכת גם בתקשורת שיתופית. מערכות חכמות המוטמעות בפלטפורמות ניהול מחזור חיי מוצר (PLM) יכולות לעקוב אחר שינויים בעיצוב, לנהל היסטוריית גרסאות ולהודיע לחברי הצוות על עדכונים בזמן אמת. צ'אטבוטים או טייסי משנה המונעים על ידי בינה מלאכותית, המשולבים בסביבות הנדסיות, יכולים לענות על שאלות, להנחות נהלי תיעוד ולהבטיח שהתקשורת תהיה בזמן ובדייקנות בין צוותים רב-תחומיים.

לסיכום, בינה מלאכותית משנה את שלב התקשורת התכנונית על ידי אוטומציה של תיעוד, שיפור ויזואליזציה ואב טיפוס, וטיפול שיתוף פעולה יעיל. יכולות אלו לא רק מייעלות את התהליך, אלא גם מבטיחות שהעיצוב הסופי מועבר בצורה ברורה ומשכנעת לכל בעלי העניין הרלוונטיים - וסוללות את הדרך לייצור, פריסה והפצת המוצר וקבלה מוצלחים בשוק.

⁴⁴ bills of materials (BOMs)

⁴⁵ and augmented/virtual reality (AR/VR) platforms

שכיחותם של אלגוריתמי בינה מלאכותית (AI) בכל שלבי התכן ההנדסי

אלגוריתמי בינה מלאכותית (AI) הפכו נפוצים יותר ויותר בכל שלבי התכן ההנדסי, והפכו זרימות עבודה מסורתיות לתהליכים חכמים, יעילים ומונעי נתונים. מהשלבים המוקדמים ביותר של הגדרת הבעיה ועד לשלבים הסופיים של תקשורת וייצור התכן, בינה מלאכותית מגדירה מחדש את האופן שבו מהנדסים מתכננים, מייעלים ומיישמים פתרונות. בשלב הגדרת הבעיה, אלגוריתמי בינה מלאכותית - ובמיוחד טכניקות עיבוד שפה טבעית (NLP) וקריית נתונים - מסייעים בזיהוי צרכי המשתמש, בניתוח נתוני פרויקט היסטוריים ובחילוץ תובנות מעשיות ממערכי נתונים גדולים ותיעוד טכני. במהלך התכן הקונספטואלי, מודלים של למידת מכונה תומכים ביצירת רעיונות מהירה על ידי יצירה והערכה של חלופות תכן רבות המבוססות על אילוצי קלט, דרישות פונקציונליות והעדפות משתמש. כלי תכן גנרטיביים המופעלים על ידי בינה מלאכותית, כגון אופטימיזציה של טופולוגיה ואלגוריתמים אבולוציוניים, חוקרים מגוון רחב של גיאומטריות אפשריות, ולעתים קרובות חושפים פתרונות חדשניים שמעצבים אנושיים עשויים שלא לשקול.

בשלב התכן המפורט, בינה מלאכותית משפרת את הדיוק על ידי תמיכה במשימות כמו ניתוח סבילות (טולרנטיות), בחירת חומרים ויצירת גיאומטריה מורכבת באמצעות מודלים ניבויים וסימולציות הנדסה בעזרת מחשב (CAE)⁴⁶. מודלים של למידה מחזקת ולמידה עמוקה מסייעים גם באופטימיזציה של אינטראקציות בין תת-מערכות ותכן מערכות בקרה. יתר על כן, בינה מלאכותית מאפשרת סימולציות בזמן אמת ויצירת אב טיפוס וירטואלי, מה שמפחית את הצורך באיטרציות פיזיות ומאיץ את זמן ההגעה לשוק. במהלך שלב התקשורת התכנונית, כלים מונעי בינה מלאכותית מאפשרים תיעוד ברור, יצירת דוחות אוטומטית והדמיה חכמה, ומבטיחים שבעלי עניין, כולל חברי צוות שאינם טכניים, יבינו את כוונת התכן. יצירת שפה טבעית וכלי ביאור משופרים של תכן בעזרת מחשב (CAD) על ידי בינה מלאכותית מייעלים את הפקת התיעוד הטכני, בעוד שמציאות רבודה (AR) והדמיה תלת-ממדית בעזרת בינה מלאכותית משפרות את מעורבות בעלי העניין ואת סקירות התכן.

יתר על כן, בינה מלאכותית תומכת בשילוב משוב מתמשך לאורך מחזור חיי התכן. לדוגמה, אלגוריתמי תחזוקה חזויים ונתונים מונעי חיישנים ממוצרים קיימים מלמדים על שיפורים איטרטיביים בתכן. בסביבות שיתופיות, בינה מלאכותית מטפחת שילוב תכן בין צוותים מבוזרים על ידי ניהול בקרת גרסאות, המלצה על שינויי תכן והבטחת עמידה בתקנים. ככל שטכנולוגיות בינה מלאכותית מתבגרות, תפקידן בשלבי תכן ההנדסי רק יעמיק, ויעביר את תפקיד המהנדס מביצוע ידני לקבלת החלטות אסטרטגיות ברמה גבוהה יותר, אימות ופיקוח על חדשנות. השילוב המקיף של בינה מלאכותית בשלבים אלה משקף שינוי פרדיגמה לעבר תהליכי תכן הנדסי חכמים, אדפטיביים ומותאמים אישית.

הערה: שלבי תכן הנדסי, שלעתים קרובות הם חלק מתהליך התכן ההנדסי הרחב יותר או מחזור חיי הפרויקט, כוללים הגדרת הבעיה, מחקר, גיבוש פתרונות, תכן מפורט, יצירת אב טיפוס, בדיקות ואיטרציות, מעבר מרעיונות רחבים (כמו הגדרה אסטרטגית) ליישום ספציפי (בנייה/ייצור) ולבסוף מסירה, תוך הבטחת נתיב מובנה מהצורך למוצר המוגמר.

⁴⁶ computer-aided engineering (CAE)

תמיכתה של בינה מלאכותית במתכננים ומעצבים אנושיים

התמיכה של בינה מלאכותית במעצבים אנושיים בהנדסה מעצבת מחדש את האופן שבו ניגשים לבעיות מורכבות, ומשפרת את היעילות וקבלת ההחלטות לאורך כל תהליך התכן. במקום להחליף מעצבים אנושיים, בינה מלאכותית פועלת כמשתפת פעולה רבת עוצמה, ומשפרת את יכולותיהם באמצעות ניתוח נתונים חכם, חישוב מהיר ויכולות יצירתיות. בשלבי הרעיון והתכן הקונספטואלי, כלי בינה מלאכותית יכולים לייצר במהירות חלופות עיצוב מרובות המבוססות על פרמטרים מוגדרים, ולעזור למעצבים לחקור מרחבי פתרונות רחבים יותר שעשויים להיות גוזלים זמן או מורכבים מדי לשקול אותם באופן ידני. אלגוריתמים של תכן יצירתי, לדוגמה, יכולים להציע מבנים או מערכות אופטימליים העומדים ביעדי ביצועים תוך הקפדה על אילוצים כמו עלות, חומרים או השפעה סביבתית. זה משחרר את המתכננים להתמקד בהערכה ובליטוש רעיונות במקום לנסח ידנית כל אפשרות.

במהלך תכן מפורט, בינה מלאכותית תומכת במהנדסים ביצירת מודלים שונים, אופטימיזציה וסימולציה. מודלים של למידת מכונה שאומנו על נתוני פרויקט היסטוריים יכולים להמליץ על תצורות רכיבים, לזהות נקודות כשל פוטנציאליות או לחזות תוצאות ביצועים בתרחישים שונים. כלי סימולציה המופעלים על ידי בינה מלאכותית יכולים להריץ איטרציות רבות עם שינויים קלים, ומציעים תובנות לגבי הגרסאות בעלות הביצועים הטובים ביותר תוך חיסכון משמעותי בזמן ובמשאבים. יכולות אלו מצמצמות את מחזורי הניסוי והטעייה, ומאפשרות למעצבים ולמתכננים לקבל החלטות מושכלות המבוססות על משוב בזמן אמת ותחזיות מבוססות נתונים.

יתר על כן, כלי בינה מלאכותית מסייעים במשימות שגרתיות וחוזרות על עצמן - כגון בחירת חלקים, אימות עיצוב ותיעוד - באמצעות אוטומציה והמלצות חכמות. לדוגמה, בינה מלאכותית יכולה לסמן באופן אוטומטי הפרות כללים במודלי CAD או להציע רכיבים העומדים בתקני התעשייה ובדרישות הרגולציה. דבר זה לא רק מגביר את הדיוק אלא גם מפחית טעויות אנוש ועומס קוגניטיבי על המהנדס המתכנן. בינה מלאכותית יכולה גם להתאים אישית תמיכה על סמך החלטות קודמות של מעצב, תוך התאמת הסיוע שלה לסגנונות והעדפות אישיות.

חשוב מכל, בינה מלאכותית משפרת את היצירתיות האנושית על ידי הקלה על מעצבים ממשימות שגרתיות והצעת חלופות בלתי צפויות שיכולות לעורר כיוונים חדשים. בעוד שבני אדם מביאים אינטואיציה, הבנה הקשרית ושיפוט אתי, בינה מלאכותית תורמת על ידי עיבוד מהיר של מערכי נתונים מורכבים וסימולציה של אינספור אפשרויות. סינרגיה זו מטפחת סביבה שיתופית שבה החדשנות מוגברת. ככל שהבינה המלאכותית ממשיכה להתפתח, תפקידה יעצים יותר ויותר מתכננים ומעצבים אנושיים להתמקד בהיבטים האסטרטגיים והאנושיים של ההנדסה, ובסופו של דבר יוביל לעיצובים יעילים, בני קיימא ויותר ממוקדי משתמש.

סיכום

לסיכום ניתן לומר שסקירת הספרות הממוקדת שבוצעה גילתה כי מחקר בנושא של תכן הנדסי זיהה את הפוטנציאל של שיטות מבוססות בינה מלאכותית לקידום מאמץ חשוב זה.

שיטות מבוססות בינה מלאכותית יושמו במשימות תכן על פני חמשת שלבי התכן.

השיטות המבוססות על בינה מלאכותית התמקדו בשלבי תכן שונים ומטרתן לשפר את תהליך התכן ההנדסי על ידי אוטומציה או הרחבה של משימות תכן מסוימות, כגון מיפוי ביקורת לקוחות לדרישות תכן, יצירת מודלים וקונספטים של תכן וניתוח עיצובים. מתוך סקר הספרות מסתבר כי למידה עמוקה היא הנפוצה ביותר מבין שבע השיטות המבוססות על בינה מלאכותית. בהתבסס על אופי משימות התכן בשלבים שונים ויכולות עיבוד הנתונים של רשתות עצביות, ניתן לראות את השיטה של למידה עמוקה ככלי בינה מלאכותית פופולרי בתחום התכן ההנדסי. בפרט, ניתן לראות כי שלבי התכן הקונספטואלי והתכן המקדים, הממנפים יצירתיות אנושית ושיתוף פעולה, היו מוקד מחקר התכן ההנדסי המבוסס על בינה מלאכותית. כמו כן, פחות עבודות תכן הנדסי מבוססות בינה מלאכותית חלות על שלבי התקשורת והמעבר של התכן. בנוסף, ראינו כי חוקרים ומתכננים בהנדסה השתמשו בכל שבע השיטות מבוססות הבינה המלאכותית בעבודותיהם בשלב התכן הקונספטואלי, דבר שעשוי להעיד על מגוון רחב של יכולות בינה מלאכותית קיימות ושיטות חדשות מבוססות בינה מלאכותית עתידיות שניתן ליישם כדי לסייע למהנדסי תכן בשלב זה. במהלך מחקר ספרות זה, מתברר גם כי השיטות מבוססות הבינה המלאכותית תמכו במתכננים בכל שלב על ידי יצירה, ניתוח ואופטימיזציה של נתוני תכן, מושגים ומודלים.

6.2. השפעות הבינה המלאכותית על תחום ההנדסה

הקשר הסימביוטי בין בינה מלאכותית להנדסה מוביל ליכולות משופרות של פתרון בעיות ולחדשנות בפרקטיקות הנדסיות. בזכות הידע הטכנולוגי שלהם, מהנדסים מסוגלים להפריך מיתוסים מסוימים סביב טכנולוגיה חדשה זו [148].

תפקידם של המהנדסים בעידן הבינה המלאכותית

מהנדסים כבר ממלאים תפקיד מרכזי יותר ויותר ברתימת הבינה המלאכותית כדי להתמודד עם אתגרים גלובליים מתפתחים ולקדם התקדמות במדע ובטכנולוגיה. המומחיות שלהם בהבנת מערכות מורכבות וידע ספציפי לתחום מאפשרים להם למנף כלי בינה מלאכותית לפתרון בעיות ואופטימיזציה של תהליכים. על ידי שילוב בינה מלאכותית בזרימות עבודה, מהנדסים מספקים פתרונות התואמים את הנופים הטכנולוגיים המתפתחים. לאחר מכן הם מסוגלים להוביל חדשנות בכל תחום שבו נעשה שימוש בהנדסה.

שיתוף פעולה בין מערכות בינה מלאכותית למהנדסים

מהנדסים מוצאים כל הזמן דרכים חדשות לשלב בינה מלאכותית בעבודתם. עבודה עם בינה מלאכותית מובילה לעלייה בפרייה, ביעילות וביצירתיות במגוון רחב של תת-תחומי הנדסה. בינה מלאכותית מטפלת ברבות מהמשימות החוזרות ונשנות שיכולות לגזול מזמנו של מהנדס. מהנדסים יכולים להתמקד בקבלת החלטות ברמה גבוהה יותר, חדשנות ופתרון בעיות.

קריירה בהנדסה בעידן הבינה המלאכותית

בעידן המונע על ידי בינה מלאכותית כיום, קריירות הנדסיות קיימות מתפתחות במהירות, עם הזדמנויות חדשות הצצות ללא הרף בתחומים מיוחדים הקשורים לבינה מלאכותית. מהנדסים הלומדים להתמחות בבינה מלאכותית מבוקשים יותר ויותר כדי למנף טכנולוגיות חדשות בתעשיות שונות.

תפקידים מתפתחים בהנדסת בינה מלאכותית

בינה מלאכותית משתנה מדי יום. ישנם תפקידים חדשים כל הזמן עבור מהנדסים לחקור, בין אם הם עבדו עם בינה מלאכותית בעבר או שהם חדשים לגמרי בתחום זה. כמה מהפופולריים ביותר כיום כוללים:

- מהנדס למידת מכונה: המומחיות שלהם טמונה בפיתוח ויישום של אלגוריתמים של למידת מכונה המנתחים ומפרשים מערכי נתונים גדולים, מניעים תובנות ומאפשרים אוטומציה של תהליכים.
- מדען נתונים: מדעני נתונים מספקים סיוע בקבלת החלטות על ידי יישום ניתוח סטטיסטי, טכניקות למידת מכונה וידע תחום על נתונים מורכבים.
- מומחה רובוטיקה: מומחה רובוטיקה מתכנן, מהנדס ומתחזק מערכות רובוטיות המופעלות על ידי בינה מלאכותית, המאפשרות אוטומציה במגוון תעשיות.
- אדריכל בינה מלאכותית: אדריכל בינה מלאכותית מתכנן ומפקח על יישום מערכות בינה מלאכותית כדי להבטיח שהן תואמות למטרות עסקיות, מפרטים טכניים וסטנדרטים אתיים.
- מערכות מידע/חכמות: אנשי מקצוע בתפקיד זה מתמקדים בתכנון מערכות המשתמשות בבינה מלאכותית כדי לנהל ולעבד מידע ביעילות כך שהנתונים הנכונים יהיו זמינים לקבלת החלטות ולמטרות תפעוליות.
- אבטחת סייבר: מומחי אבטחת סייבר ממנפים בינה מלאכותית כדי לשפר את אמצעי האבטחה, לזהות ולהגיב לאיומי סייבר ולהגן על נתונים מפני פרוצדורות פוטנציאליות.
- מדעי המחשב: תחום רחב זה כולל תפקידים כגון מפתחי תוכנה וחוקרים המקדמים טכנולוגיות בינה מלאכותית ומשלבים אותן ביישומים שונים.


מיומנויות והכשרה להנדסה מונחית בינה מלאכותית

כמו תת-תחומים רבים אחרים בהנדסה, מעסיקים מחפשים מיומנויות ספציפיות אצל מועמדים פוטנציאליים לעבודה הקשורה לבינה מלאכותית, אפילו כאלה עם ניסיון הנדסי נרחב. רשימה זו אינה ממצה כלל, אך זוהי נקודת התחלה טובה עבור מהנדסים נוכחיים השוקלים מעבר לתחומים הקשורים לבינה מלאכותית.

- תכנות: שליטה בשפות תכנות כמו Python, Java או R נדרשת כמעט באופן אוניברסלי לפיתוח אלגוריתמים של בינה מלאכותית. שפות אלו מהוות את הבסיס למודלי למידה חשמלית ולמשימות עיבוד נתונים גדולות.
- ניתוח נתונים: מהנדסים זקוקים למיומנויות אנליטיות חזקות כדי להפיק תובנות מנתונים, לזהות דפוסים ולקבל החלטות מבוססות נתונים. מהנדסים צריכים להיות בעלי ניסיון נרחב בשימוש בכלים כמו SQL, Pandas או Tableau.
- שיתוף פעולה בין-תחומי: אחת ה"מיומנויות הרכות" הנדרשות במשרות המתמקדות בבינה מלאכותית היא היכולת לעבוד כחלק מצוות. מהנדסים משתפים פעולה לעתים קרובות עם מדעני נתונים, מומחי תחום, אנשי מקצוע בתחום העיצוב ובעלי עניין עסקיים כדי לפתח פתרונות מקיפים העונים על צרכים ודרישות מגוונים.

7. השפעת הבינה המלאכותית על תהליכי תכן הנדסי עבור מערכות דינמיות

שינויים מבניים, מחזורי פיתוח קצרים יותר ואתגרים רב-תחומיים הולכים וגדלים דורשים גישות חדשניות לתכן מוצר. תכן עתידי של מערכות בהנדסה חייב להיות רב-תחומי, לא רק על מנת לעמוד בדרישות הלקוחות העתידיות, בתקנות חדשות ובאחריות חברתית, אלא גם כדי להפיק את התועלת המיטבית מהאפשרויות הטכניות של סוגי מערכות חדשים עם רכיבי בינה מלאכותית (AI) משולבים [5]. מכיוון ששיטות בינה מלאכותית מקורן באלגוריתמים מתמטיים, בתחילה, הן אינן מותאמות לתחומים מסוימים, אלא עוקבות אחר עקרונות כלליים שהופכים אותן לניתנות ליישום לתחומים השונים וכן ברמת האינטגרציה. בתחום המכטרוני, כמו גם בתחומים הנדסיים נוספים, נעשית התאמה של מודל ה-V המפורסם ליישום באמצעות כלי בינה מלאכותית (ראה האיור אשר מתאר את תהליך תכן מודל V המקובל בתחום זה כמו גם בכלל בהנדסת מערכת).




איור 7-1 - מודל V לתכן מכטרוני לפי הנחיית VDI 2206 [14,7]

Source: The impact of AI on engineering design procedures for dynamical systems

https://www.researchgate.net/publication/387141113_The_impact_of_AI_on_engineering_design_procedures_for_dynamical_systems

תכן מערכות עתידי יושג על ידי אוטומציה (חלקית) של תהליך התכן: (1) אסטרטגיות אופטימיזציה נומריות ישתלטו על החיפוש אחר פתרונות הפשרה הטובים ביותר, (2) שיטות ניתוח מתחומים שונים משולבות להערכת מערכות, ו-(3) אלגוריתמים משופרים בבינה מלאכותית יוחלו להערכת ובקרה של דינמיקת המערכת, כמו גם להחלטות תכן [4].



איור 7-2 - בתכן מכטרוני, שיטות בינה מלאכותית מקושרות קשר הדוק הן לניסויים והן לסימולציות

Source: The impact of AI on engineering design procedures for dynamical systems

https://www.researchgate.net/publication/387141113_The_impact_of_AI_on_engineering_design_procedures_for_dynamical_systems

תכן מערכות טכנולוגיות חדשניות הוא אחד ההישגים היצירתיים התובעניים ביותר בהנדסה. כיום, סיוע בכלים מבוססי נתונים מוגבל בעיקר לניתוח מערכות. לפיכך, תהליך הפיתוח הטיפוסי מתממש באופי אינטראקטיבי: ראשית, מתבצעים מחקרי פרמטרים גוזלי זמן, לאחר מכן, תוצאות הסימולציה מוערכות באופן ידני וסובייקטיבי, מה שמוביל לשינויים איטרטיביים בתכן הנוכחי המבוססים על ידע מומחה. התוצאה מוכרזת לעתים קרובות כ"אופטימלית", דבר שנראה מפקפק מכמה היבטים: (i) באופן כללי, ההערכה מבוססת על קריטריונים סובייקטיביים ולא על קריטריונים אובייקטיביים המתוארים מתמטית; (ii) חוסר היכולת האנושי לזהות קורלציות במרחבי תכן ממדיים גבוהים יותר, כמו גם אילוצי זמן בתהליך הפיתוח התעשייתי, מונעים השגת אופטימום; (iii) המומחיות של מהנדס תכן מוגבלת בדרך כלל לתחום אחד או רק למספר תת-תחומים. תהליך תכן בסיוע בינה מלאכותית מספק הזדמנות להתגבר על חסרונות אלה [56]. יתר על כן, הוא מאפשר התחשבות בקריטריונים שונים של תכן כבר בשלבי תכן מוקדמים, אשר בעבר נלקחו בחשבון רק בשלב מאוחר יותר. דבר זה עשוי, בזמנית, לתרום לתוצאות תכן טובות יותר ולזמני פיתוח קצרים יותר.

לפיכך, מתודולוגיות תכן מערכות עתידיות צריכות לתאם את יחסי הגומלין בין ניסויים, סימולציות מבוססות מודל ושיטות בינה מלאכותית כפי שמודגם באיור 7.2. באופן קלאסי, תכן טכני התבסס במידה רבה על ניסויים. טכניקות סימולציה נומריות עבור מודלים מבוססי פיזיקה יכולות להפחית את מספר הניסויים, להרחיב מעבר לאבות טיפוס קיימים, או לבדוק עיצובים במצבים קיצוניים, שקשה לשחזר בניסויים פיזיקליים. מצד שני, יש לאמת את התוצאות המבוססות על מודל על ידי ניסויים אמיתיים. עם זאת, עבור מערכות מורכבות, לעתים קרובות יש מחסור במודלים מתאימים, או שהסימולציות הקיימות כה נרחבות וגוזלות זמן עד שניתוחי מערכת שיטתיים הופכים ללא מעשיים. בנוסף, קביעת פרמטרי המודל הנדרשים היא קשה ומייגעת. השפעות מעוותות, מפריעות ומוסתרות בניסויים מונעות לעיתים קרובות פרשנות פשוטה. כמויות

עצומות של נתוני מדידה דורשות עיבוד נתונים אוטומטי ואינטליגנטי, פוטנציאלית באמצעות גישות כריית נתונים.

במקביל לגישות אלו, הנוף הנוכחי של פיתוח מוצרים חווה השפעה ניכרת ממתודולוגיות של בינה מלאכותית. למידת מכונה (ML), ענף של בינה מלאכותית, משמשת לחיזוי ואופטימיזציה של תוצאות בסביבות מדומות [6]. אלגוריתמים אלו יכולים להבחין בדפוסים מורכבים ובקשרים בתוך נתוני סימולציה, מה שמאפשר תחזיות מדויקות יותר של התנהגות המוצר. בנוסף, סימולציות מונחות בינה מלאכותית מאפשרות אופטימיזציה אוטומטית של פרמטרים, ומאיצות את תהליך התכן האיטרטיבי. יכולת ההסתגלות של בינה מלאכותית מאפשרת לסימולציות ללמוד מנתונים מתפתחים, ומספקת מסגרת דינמית וחכמה לבדיקות וירטואליות [11]. יתר על כן, במרחבים פרמטריים בעלי ממדים גבוהים, שיטות בינה מלאכותית הן חלופות מבטיחות בתחום תכן הניסויים. לפיכך, עבור תכן מערכות, אין דרך אחת בעלת יתרון על פני האחרות, אלא שילוב של שיטות זמינות ומתאימות ביותר ישפר את תהליך התכן.

תפיסה מתקדמת בתחום תכן מוצרים הנדסיים⁴⁷

ההנחיות VDI 2221 ו-VDI 2206 [14], המקובלות בגרמניה, נוצרו במטרה לתכנן וליישם את תכן המוצרים הטכניים, ובפרט מערכות מכטרוניות, ביעילות ובאמינות הן מבחינת זמן והן מבחינת עלויות. הן מסכמות ניסיון מעשי וגישות מדעיות. מודל ה-V, ראה איורים 7.1, 7.2, שמקורם בפיתוח תוכנה, מייצגים גישה נפוצה למתודולוגיית תכן. נקודת המוצא של תהליך תכן היא גילוי הדרישות, המתועדת במפרט. בעוד שבעבר, הדרישות נותרו סטטיות במהלך תהליך התכן, כיום, המורכבות המוגברת של המערכת אינה מאפשרת לקבוע את הדרישות בשלב מוקדם. במקום זאת, התאמה גמישה במהלך תהליך התכן מיושמת כלולאות משוב, ראה איור 7.2.

האגף השמאלי של ה-V מייצג את שלבי התכן המוקדמים (תכן גס). כאן, החל בייצוג מופשט (שאינו תלוי בפתרון) של המשימה, מושג המערכת או ארכיטקטורת המערכת מוגדרים על ידי פירוקם לתת-משימות והקצאת מבני פתרון לפונקציות הבודדות. מכיוון שכל תת-פונקציה ניתנת למימוש על ידי פתרונות רבים מתחומים פיזיים שונים, התוצאה היא מרחב פתרונות שגדל במהירות, שגודלו גדל באופן אקספוננציאלי עם מספר תת-המבנים. בנוסף לפונקציות העיקריות של הפתרונות, יש לקחת בחשבון גם פונקציות משניות ואינטראקציות עם תת-המבנים האחרים. הניסיון והיצירתיות של המפתחים מגדילים את סיכויי ההצלחה. גישות תכן מקובלות מבוססות על מטריצות שילוב, או על מודלים אנליטיים פשוטים עם פרמטרים אופייניים [9].

התכנונים הספציפיים לתחום (תכן מפורט) מוצגים בחלק התחתון של ה-V. אלה מבוצעים במקביל על ידי מומחים ובעלי רמת פירוט גבוהה. במקרה של מערכות מכטרוניות, בדרך כלל מתבצעים תכן מכני (מבני), תכן אלקטרוני ותכן תוכנה⁴⁸. בהתאם לתכן המערכת, ניתן להוסיף תחומים נוספים, למשל, דינמיקת נוזלים,

⁴⁷ The impact of AI on engineering design procedures for dynamical systems (SOURCE)

⁴⁸ "מתודולוגיית אג'יל" (Agile) היא גישה מודרנית בניהול פרויקטים ופיתוח תוכנה לשיפור היכולת הציווית והארגונית של החברה, מה שמוביל למתן שירות טוב יותר עבור הלקוחות של החברה.

מגנטיקה או אופטיקה. קיימות גישות וכלים מיוחדים לתכן לכל תחום. לדוגמה, כלי תכן בעזרת מחשב (CAD)⁴⁹ או ניתוחי חוזק באמצעות שיטת אלמנטים סופיים (FEM)⁵⁰ משמשים בתכן מכני. סימולטורים כגון תוכנת סימולציה עם דגש על מעגלים משולבים (SPICE)⁵¹ או תוכנת ניתוח לתכן מעגלים. סביבות פיתוח משולבות⁵² GitHub, (IDE) וכלי יצירת קוד ובדיקה אוטומטיים מסייעים בפיתוח תוכנה. תכנוני התחומים המפורטים משולבים באגף הימני של ה-V באינטגרציית המערכת. הודות לידע הספציפי של כל תת-המערכות, ניתן לחזות במדויק את התנהגות המערכת באופן סטטי ודינמי. יתר על כן, ניתן להגדיר פרמטרים לבקרים. סימולציות אנלוגיות כגון MATLAB או Simplora מסייעות בכך. תכונות המערכת מושוות למפרט באמצעות אימות (השוואת תכונות המערכת למפרט ברמות שונות של מערכת אמיתית) ותיקוף (סקירה בנוגע לשימוש או תועלת שמוגדרים מראש). תהליך התכן מסתיים במעבר נתוני התכן לתכן הייצור או ללולאות תכן נוספות.

תהליך התכן מלווה במידול וניתוח (סימולציה) כפי שמתואר בצד התחתון של מודל ה-V. כפי שצוין בתיאור הקודם, קיימים מודלים בעלי רמות פירוט ודיוק שונות עבור כל שלב. נדרש ניהול נתונים רציף כדי לעבד תוצאות של שלב אחד ולהכין אותן כקלט לשלב הבא. זה מתממש לעתים קרובות על ידי סקריפטים ומסדי נתונים פשוטים, ומנותחים על ידי חבילות תוכנה קנייניות. המודלים מאומתים ומאוחסנים עם הפרמטרים הספציפיים עבור המוצר המפותח כ-digital twin.

מודל ה-V פותח בארה"ב על ידי בארי וו. בוהם וקווין בשנת 1979, ועל ידי פורסברג ביחד עם הרולד מוז בשנת 1990 ובמקביל על ידי איגוד המהנדסים הגרמני (VDI). יש לו מספר פיתוחים נוספים והתאמות ספציפיות, למשל, עבור מערכות מיקרו-אלקטרו-מכניות (MEMS), או מערכות ייצור מאורגנות עצמית בשלבים מוקדמים של פיתוח מוצרים בין-תחומיים. רק לאחרונה מוצע עדכון של מודל ה-V לאור שיטות בינה מלאכותית, ראו למשל, [8].

פוטנציאל לשילוב בינה מלאכותית בתהליך התכן

שיטות בינה מלאכותית כבר הראו הצלחה רבה בזיהוי והפרדת תבניות, יצירת טקסט ותמונה ותחומים אחרים. בעיצוב מוצרים תעשייתיים, גישות אלו טרם נוצלו. עם זאת, הן מציעות מספר הזדמנויות מעניינות לשיפור תהליך התכן ההנדסי. ארכיטקטורת המערכת באיור 7.2 היא תהליך סינתזה. כמעט ואין כלים תומכים למציאת התצורה הטובה ביותר של פתרונות עבור תת-פונקציות. מרחב הפתרונות גדל באופן אקספוננציאלי עם מספר תת-פונקציות. הניסיון והאינטואיציה של המעצבים האנושיים, שהם בעיקר מומחים במספר מועט של תחומים טכניים, יכולים להיות מוגבלים רק לתת-מרחב. לדוגמה, DMG lib⁵³, אסף יותר מ-3000 מנגנונים שונים, חלקם מפטנטים נשכחים או פאנלים היסטוריים [9]. לעתים קרובות, תחומים שונים מתחרים בפתרונות עבור תת-פונקציה, למשל, מנגנון עם הנעה סטנדרטית לעומת שילוב של הנעות חכמות מבוקרות,

⁴⁹ computer aided design (CAD)

⁵⁰ finite element method (FEM)

⁵¹ Simulation program with integrated circuit emphasis (SPICE)

⁵² Integrated development environments (IDE)

⁵³ Digital Mechanism and Gear Library <https://www.dmg-lib.org/dmglib/main/portal.jsp>

או חיישן פיזי לעומת צופה בלולאת משוב. בינה מלאכותית יכולה לסייע באמצעות מסד הנתונים העצום שלה בזיהוי שילובים מתאימים של פתרונות עבור כל תת-פונקציות ומתחומים שונים. כמו כן, התכן הספציפי לתחום באיור 7.1 הוא תהליך סינתזה שבו יש לציין מספר עצום של פרמטרים מתוך מספר מועט של פרמטרי קלט בלבד. מצד אחד, זהו תהליך אופטימיזציה, לרוב עם פונקציית יעד מרובת קריטריונים. גישות אופטימיזציה מתמטית קלאסיות מוגבלות על ידי זמני חישוב עצומים ועל ידי טיפול בקריטריונים שונים. מצד שני, המודלים המשמשים בתכן ספציפי לתחום צריכים להיות מדויקים מאוד. לעתים קרובות הם אינם ליניאריים ומכילים פרמטרים חומריים משוערים. במקרים מסוימים, הגישה הפיזיקלית תקפה רק עבור טווח מוגבל של משתני המערכת או אפילו אינה ידועה לחלוטין. גישות בינה מלאכותית לתהליך התכן טומנות בחובן פוטנציאל גדול להאצה ולשינוי גישות מסורתיות. היכולת של בינה מלאכותית לנתח מערכי נתונים עצומים, לזהות דפוסים ולמטב פתרונות בזמן אמת הופכת אותה לכלי משנה משחק להגברת היעילות והיצירתיות בתכן.

הסעיפים הבאים בוחנים את המצב הנוכחי של יישומי בינה מלאכותית, ומדגישים את הפוטנציאל לשיפורים בתהליך התכן. בהתייחס למודל ה-V באיור 7.1, ראינו כיום ששיטות בינה מלאכותית משמשות בעיקר בשלבי הפיתוח המוקדמים.

תכן מבוסס מודל, המאפשר צמצום ניסויי מעבדה ויצירת אב טיפוס מינימלית, עשוי להתנגש עם שיטות בינה מלאכותית הרעבות לנתונים. כאן, יצירת נתונים סינתטיים מספקת אפשרויות לפתרונות. ראה סעיף 7.1.1 לאחר מכן, ניתן להשתמש במודל מבוסס בינה מלאכותית או מודל היברידי עבור בעיות תכן או יישום ספציפיות לתחום ברמות הפשטה שונות, ראה סעיפים 7.1.2 ו-7.1.3. בלולאות אינטגרציה או אימות של מערכות, ניתן ליישם טכניקות זיהוי, אופטימיזציה ובקרה, כמו גם שיטות למידה לחיזוק, ראה סעיף **זיהוי, אופטימיזציה ובקרה בסיוע בינה מלאכותית.**

1. השלמת נתונים ניסיוניים באמצעות נתונים סינתטיים

כדי לפתח כלי חיזוי חזקים באמצעות שיטות למידת מכונה (ML), מערכי נתונים עקביים, מדויקים ועשירים הם תנאי הכרחי. השימוש בשיטות מבוססות למידה חישובית בתחומי הנדסה מסורתיים הוגבל עקב מחסור במערכי נתונים, מכיוון שביצוע ניסויים יכול לגזול זמן ויקר. בעוד שנתונים ניסיוניים מייצגים את כל ההשפעות הפיזיקליות הקיימות במערכת, הם יכולים גם לסבול מרעש, הטיות וחוסר עקביות. יתר על כן, יכולת צפייה מוגבלת של כל מצבי המערכת הרלוונטיים יכולה להיות בעיה. מודלים מספריים יכולים להתגבר על חלק ממגבלות הניסויים ולספק נתונים רבים לאימון מודלי למידת מכונה, תוך סיכון פוטנציאלי להכנסת הסטת תחום. יתר על כן, בהתאם למורכבות הבעיה, גם מודלים, למשל מודלי FEM, יכולים לגרור עלויות גבוהות עקב זמן חישובי רב. מודלים מבוססי למידה גנרטיבית יכולים להתגבר על מגבלות אלה על ידי אימון על הנתונים המוגבלים המתקבלים מניסויים וסימולציות ויצירת נתונים סינתטיים מציאותיים. מודלים אלה צברו תאוצה רבה בשנים האחרונות בשל יכולתם לדמות את התפלגות הנתונים בפועל וליצור נקודות נתונים חדשות, במקום לדמות רק את גבול ההחלטה בין מחלקות. עם זאת, מודלים גנרטיביים אלה לא יושמו באופן נרחב בתחומי הנדסה. קיימים מספר מחקרים בספרות שהשתמשו ברשתות גנרטיביות יריבות (GAN) כדי להשלים נתונים בתחום ההנדסה [24].

2. מידול מבוסס בינה מלאכותית

נושא מרכזי בלמידת מכונה מפוקחת הוא קירוב של פונקציה לא ידועה מנתוני אימון. פונקציה כזו מקבלת קלט (למשל, מדידות מתהליך ייצור כגון טמפרטורות או מאמצים) ומייצרת פלט (למשל, ההצהרה האם המוצר הוא באיכות גבוהה או לא). בהינתן נתונים, מטרת למידת מכונה היא לאמן מודל המסוגל לחזות את פלט הפונקציה עבור קלטים שלא נראו קודם לכן. מטרת סעיף זה היא לשפוך אור על המספר הרב של גישות וטכניקות שהופיעו בשנים האחרונות בהקשר של מידול מערכות מורכבות.

3. מידול חלופי וצמצום ממדיות

בדומה לדוגמה שתוארה לעיל, ניתן להציג גם את מידול מערכות מורכבות כבעיית קירוב פונקציות. מספר רב של מערכות הנדסיות ניתנות לתיאור על ידי משוואות דיפרנציאליות, שבהן הנגזרות של מצב המערכת X כנגד הזמן (משוואות דיפרנציאליות רגילות)⁵⁴ או כנגד המרחב והזמן (משוואות דיפרנציאליות חלקיות)⁵⁵ יוצרות קשר פונקציונלי עם המצב עצמו. דוגמאות למערכות המתוארות על ידי ODEs הן דינמיקה של מערכות מרובות גופים, תנועות רובוטים או דינמיקה מולקולרית. PDEs⁵⁶, לעומת זאת, מתארים תופעות מבוזרות כגון זרימת חום או מכניקת רצף.

תחומי יישום

כדי להמחיש את יישום הטכניקות הללו של סימולציה, להלן מספר דוגמאות חשוב לשים לב לפוטנציאל לשימוש בטכניקות מידול ואופטימיזציה מבוססות בינה מלאכותית, כמו גם לאתגרים ספציפיים ליישום [8, 52].

הנדסת מכונות: תכן מגננונים מכניים הוא משימה מאתגרת, שכן קשרים ומבנים נעים אחרים כפופים לאילוצים פיזיקליים מורכבים ולעתים קרובות מציגים אפשרויות עיצוב נפרדות. בנוסף, הקשר בין התנועה לתכן המגננון יכול להיות לא ליניארי מאוד, במיוחד בגבול בין סוגי מגננונים שונים. כתוצאה מכך, עשויים להתקיים פתרונות מרובים - פוטנציאליים מנותקים מבחינה טופולוגית - עבור משימה נתונה. אף על פי כן, מכונות ייעודיות שתוכננו בקפידה יכולות להיות קלות יותר, חסכוניות יותר באנרגיה, קלות יותר לשליטה ומדויקות יותר בהשוואה למערכות ייעודיות.

רובטיקה ומכטרוניקה: בתכן מערכות רובוטיות, ביצועים רצויים מאופיינים לעתים קרובות במהירות ויעילות אנרגטית. מתוך מחשבה על מטרות אלו, תכן מערכות רובוטיות יכול להיות מאתגר, שכן חומרת המערכות (כלומר, המורפולוגיה) והבקרה הנלווית (כלומר, התנועה) קשורות זו לזו באופן אינהרנטי באמצעות דינמיקה המכנית. כתוצאה מכך, יש ליישם גישת תכן משותפת כדי לייעל בו זמנית הן את התנועה והן את המורפולוגיה. אם רצוי מערך מגוון של משימות, גישה זו חייבת להתפשר על תכן מכני יחיד כדי לתמוך בצורה אופטימלית בתנועות שונות שהרובוט צריך כדי לבצע ביעילות. אופטימיזציות מרובות משימות כאלה יכולות

⁵⁴ ordinary differential equations (ODEs)

⁵⁵ partial differential equations (PDEs)

⁵⁶ Partial Differential Equations (PDEs)

להוביל לבעיות אופטימיזציה מורכבות, ורבות ממדים. פתרון בעיות אלו דרש באופן מסורתי התערבות אנושית משמעותית וידע מומחה כדי לזהות עיצובים רובוטיים מתאימים. לאחרונה, **בינה מלאכותית (AI)** הפכה למרכיב חשוב בתהליכי התכן של מערכות רובוטיות. היישומים של טכניקות למידת מכונה (ML) נעים בין אלגוריתמים גנטיים להתקדמות עדכנית יותר בלמידת חיזוק עמוקה. כדי לסייע בגישות מסורתיות מבוססות אופטימיזציה לתכן משותף, טכניקות מידול מבוססות בינה מלאכותית, כפי שתואר לעיל, יכולות לסייע בהקלת הנטל החישובי. כאן, עדיפים מודלים המאפשרים הערכת מידע רגיש כפי שהוא נחוץ באופטימיזציה ובקרה.

מכניקת זרימה⁵⁷: מידול ותכן מערכות בדינמיקת זורמים הוא משימה מאתגרת ביותר, כאשר אחד האתגרים המרכזיים הוא פיזיקת הזרימה המורכבת הנשלטת על ידי משוואות נאווייר-סטוקס (Navier-Stokes equations) בצורות שונות (לא דחיסה/דחיסה, מגיבה/לא מגיבה וכו', בהתאם ליישום הספציפי).

במשטרים הרלוונטיים ליישומים, הזרימות הן בדרך כלל טורבולנטיות. משמעות הדבר היא שעלינו להתמודד עם פיזיקה מורכבת רב-ממדית הן במרחב והן בזמן, וחישובים עולים במהירות על יכולות המחשוב המודרניות אפילו במחשבים בעלי ביצועים גבוהים. בשל כך, בינה מלאכותית הפכה לגורם חשוב בתהליכי תכן עבור מערכות הנשלטות על ידי מכניקת זורמים. ניתן לחלק את השימוש בלמידת מכונה במכניקת זורמים [116,117] למספר קטגוריות. משוואות התנועה ידועות היטב, אך בדרך כלל יקרות מדי לפתרון נומרי, ולכן אחת המטרות המרכזיות היא להאיץ סימולציות.

זיהוי, אופטימיזציה ובקרה בסיוע בינה מלאכותית

בהקשר תעשייתי, התכן מבוסס בדרך כלל על מומחיות ומונע על ידי הליך ניסוי וטעייה. שינויים קטנים בפרמטר תכן אחד או בכמה פרמטרים מנותחים באמצעות תוכנה מסחרית מוכנה (CoTS)⁵⁸ או תהליכי ניתוח רב-תחומיים, שלעתים קרובות גוזלת זמן, על מנת לצבור ידע על שיפור והחמרה של שינויי תכן. עם זאת, במרחבי תכן בעלי ממדים גבוהים, הליך כזה גוזל זמן רב ולעתים רחוקות הוא יוביל לתכן אופטימלי באמת. לכן, החלפה על ידי אופטימיזציה מספרית מרובת קריטריונים היא הפתרון הטוב יותר. במיוחד אלגוריתמים מבוססי אוכלוסייה, כגון אלגוריתמים גנטיים מרובי קריטריונים או אופטימיזציה של נחיל חלקיקים, מסוגלים להשיג פשרות אופטימליות גם במקרה של פונקציות מטרה רב-מודאליות ומרחבי תכן הטרוגניים.

⁵⁷ Fluid mechanics

⁵⁸ Commercial-off-the-shelf or commercially available off-the-shelf (COTS) products are packaged or canned (ready-made) hardware or software.

8. השפעת בינה מלאכותית על תהליכי תכן בתוכנה

התחום בו השפעתה של הבינה המלאכותית היא המשמעותית ביותר הוא, ולא באופן מפתיע, הוא הנדסת התוכנה. בינה מלאכותית שינתה באופן משמעותי את פיתוח התוכנה על ידי אוטומציה של משימות שגרתיות, שיפור איכות הקוד ושיפור ניהול הפרויקטים. היא מאפשרת ניבוי לקבלת החלטות טובה יותר ומטפחת גישות חדשניות ביצירת תוכנה, מה שמוביל לתהליכי פיתוח יעילים ומתקדמים יותר ומאפשרת למפתחים להתמקד בהיבטים חדשניים ומורכבים של ארכיטקטורת תוכנה.

אפשר לשאול האם בינה מלאכותית "תשתלט" על פיתוח התוכנה והתשובה היא - לא. במקום זאת, היא פועלת ככלי רב עוצמה המשפר את יכולותיהם של מפתחים אנושיים. בינה מלאכותית הופכת משימות שגרתיות לאוטומטיות ומציעה תובנות אנליטיות, אך פתרון בעיות יצירתי, תכן אסטרטגי וקבלת החלטות מורכבות נותרים תלויים במומחיות ובאינטואיציה אנושית בפיתוח תוכנה.

לאור האמור לעיל אפשר לומר שבפועל מהסקר שאנו מבצעים ניתן לראות שאימוץ הבינה המלאכותית בפיתוח תוכנה הוא שינוי משמעותי שמוביל לעידן חדש של חדשנות ויעילות משופרת. חיוני שאנשי מקצוע בתחום הטכנולוגיה יאמצו את השינוי הזה כדי להישאר צעד אחד קדימה בתחום. להיות מעודכנים וגמישים הם המפתח לניצול מיטבי של היכולות המתפתחות של הבינה המלאכותית.

בינה מלאכותית (AI) התפתחה במהירות לכוח טרנספורמטיבי בתחומים רבים, ותכן תוכנה אינו יוצא מן הכלל. שילוב הבינה המלאכותית בתהליכי תכן תוכנה מחולל מהפכה באופן שבו מערכות תוכנה נתפסות, מפותחות, נבדקות ומתוחזקות. טכנולוגיות בינה מלאכותית - ובמיוחד למידת מכונה (ML), עיבוד שפה טבעית (NLP), למידה עמוקה ומודלים גדולים של שפה - (LLM) מעצבות מחדש זרימות עבודה מסורתיות, משפרות את הפרודוקטיביות, מאפשרות אוטומציה ופותרות פרדיגמות חדשות בשיתוף פעולה בין אדם למחשב. ככל שארגונים מתמודדים עם לחץ גובר לבנות מערכות תוכנה מורכבות, ניתנות להרחבה וגמישות במהירות, בינה מלאכותית מציעה נתיב להשגת מטרות אלו בצורה יעילה וחכמה יותר.

בליבה של השפעת הבינה המלאכותית על עיצוב תוכנה טמונה אוטומציה והרחבת משימות שגרתיות. עיצוב תוכנה מסורתי כרוך לעתים קרובות בפעילויות עתירות עבודה כגון ניתוח דרישות, יצירת אב טיפוס של ממשק משתמש (UI)⁵⁹, מידול מערכות ויצירת קוד. כלי בינה מלאכותית הופכים כיום לאוטומטיים רבים מהשלבים הללו. לדוגמה GitHub Copilot⁶⁰ המופעל על ידי מודל Codex של OpenAI, יכול להשלים באופן אוטומטי קטעי קוד, ליצור פונקציות סטנדרטיות ואפילו לכתוב מתודות שלמות המבוססות על הנחיות בשפה טבעית. כלים כאלה מאפשרים למפתחים להתמקד בחשיבה עיצובית מסדר גבוה יותר תוך העברת משימות קידוד חוזרות ונשנות לבינה המלאכותית. מודל Co-pilot זה לא רק מגביר את הפרודוקטיביות אלא גם הופך את פיתוח התוכנה לדמוקרטיזציה על ידי הורדת חסם הכניסה עבור אנשים שאינם מתכנתים [66].

⁵⁹ user interface (UI)

⁶⁰ AI that builds with you. <https://github.com/features/copilot>

8.1. המעבר מהנדסה מבוססת כללים לפיתוח מונחה נתונים

אחד השינויים המשמעותיים ביותר שבינה מלאכותית מביאה לעיצוב תוכנה הוא המעבר מהנדסה מבוססת כללים לפיתוח מונחה נתונים. שיטות עיצוב תוכנה מסורתיות מדגישות כללים פורמליים, תהליכים מובנים ומידול דטרמיניסטי. לעומת זאת, עיצוב המונע על ידי בינה מלאכותית ממנף מערכי נתונים גדולים ולמידה סטטיסטית כדי להסיק דפוסים ולמטב את התנהגות המערכת. לדוגמה, בעיצוב ממשק משתמש, בינה מלאכותית יכולה לנתח נתוני שימוש כדי להמליץ על שיפורי פריסה, מיקומי כפתורים או זרימת אינטראקציה המבוססת על התנהגות משתמש במקום היוריסטיות⁶¹ או שיטות מוגדרות מראש. AutoML של גוגל, Azure ML של מיקרוסופט ופלטפורמות דומות מספקות כעת למפתחים כלים לתכנן ולפריסה של מודלים של למידת מכונה עם קידוד מינימלי, תוך שילוב התנהגות חכמה ישירות במערכות תוכנה משלב התכנן.

בינה מלאכותית גם מגדירה מחדש את הנדסת הדרישות, השלב הבסיסי בעיצוב תוכנה. חילוץ דרישות מדויקות מבעלי עניין הוא באופן מסורתי מועד לטעויות וגוזל זמן. אלגוריתמי עיבוד שפה טבעית (NLP) יכולים כעת לנתח נתונים לא מובנים - כגון תמלילי פגישות, משוב לקוחות או מסמכים משפטיים - כדי לזהות דרישות מפתח, לזהות חוסר עקביות ואף להציע מערכי תכונות. כלים כמו IBM Watson ו-ChatGPT יכולים לעבד כמות עצומה של טקסט ולסייע בהמרת צרכי בעלי עניין לא פורמליים לדרישות תוכנה פורמליות. יתר על כן, ניתוח דרישות מבוסס בינה מלאכותית יכול לזהות סתירות או אי-בהירויות בשלב מוקדם של מחזור חיי התכנן, ובכך להפחית שגיאות יקרות במורד הזרם⁶².

תחום נוסף שבו לבינה מלאכותית יש השפעה עמוקה הוא אדריכלות וקבלת החלטות עיצוביות⁶³. אדריכלות תוכנה כרוכה בפשרות מורכבות בין ביצועים, מדרגיות, תחזוקה ועלות. בינה מלאכותית יכולה לסייע לאדריכלים על ידי סימולציה של עיצובים חלופיים וחיזוי השפעתם. לדוגמה, סוכני למידה חיזוקית יכולים להעריך תצורות ארכיטקטוניות שונות ולהציע דפוסים אופטימליים עבור ארכיטקטורות מערכות מבוזרות או מיקרו-שירותים. מודלים של בינה מלאכותית יכולים גם להעריך נתוני פרויקט היסטוריים ולהמליץ על מסגרות או דפוסי עיצוב שהצליחו היטב בהקשרים דומים. יתר על כן, כלים כמו

⁶⁵ DeepCode (now part of Snyk) ⁶⁴ Amazon CodeGuru מיישמים למידת מכונה לניתוח קוד מקור, ומציעים הצעות עיצוב ומזהים פגמים אדריכליים. יצירת קוד היא אולי התחום הבולט ביותר שבו בינה

⁶¹ Heuristics are mental shortcuts people use that simplify problems and help them avoid cognitive overload.

<https://www.investopedia.com/terms/h/heuristics.asp>

⁶² Natural Language Processing for Requirements Engineering: A Systematic Mapping Study

https://pure.manchester.ac.uk/ws/portalfiles/portal/183513868/2020_12_16_NLP4RE_Accepted.pdf

⁶³ 10 AI Code Review Tools That Find Bugs & Flaws in 2025. Published: June 18, 2025

<https://www.digitalocean.com/resources/articles/ai-code-review-tools>

⁶⁴ Amazon CodeGuru is an AWS service that helps improve code quality and application performance using machine learning. It has two main components: : [CodeGuru Reviewer](#) and [CodeGuru Profiler](#).

⁶⁵ DeepCode (now part of Snyk) is an AI-powered code review tool that analyzes code in real time, providing suggestions and identifying potential issues. The platform excels in security-focused code analysis. ([SOURCE](#))

מלאכותית עשתה צעדים אדירים. מעבר להשלמה אוטומטית, מודלים גנרטיביים כותבים כיום חלקים גדולים של קוד מתיאורי שפה טבעית או מדגמים חזותיים. כלים כמו DeepMind's AlphaCode, OpenAI's Codex, Meta's Code Llama, מדגימים מגמה זו. מודלים אלה מאומנים על מיליארדי שורות של קוד פתוח ובעלי שטף יוצא דופן בשפות תכנות, מה שמאפשר להם לשמש כמתכנתים זוגיים משתפי פעולה של בינה מלאכותית. במקרים רבים, הם יכולים להפוך סקיצות של wireframe לתבניות HTML/CSS או ליצור לוגיקה של backend מסיפורי משתמש. ככל שמודלים אלה משתפרים, הם מסוגלים יותר ויותר לייצר קוד מאובטח, יעיל וקריא, ומשנים באופן מהותי את זרימת העבודה של עיצוב תוכנה [145].

בתחום הבדיקות והאימות, בינה מלאכותית מאיצה ומשפרת את תהליך אבטחת האיכות. בדיקות תוכנה מסורתיות כרוכות לעתים קרובות בכתיבה ידנית של בדיקות יחידה, בדיקות אינטגרציה ומבחני ממשק משתמש. כלים התומכים בבינה מלאכותית יכולים ליצור מקרי בדיקה באופן אוטומטי על ידי ניתוח קוד מקור ולמידה מדפוסי בדיקה קודמים. לדוגמה, Diffblue Cover⁶⁶ משתמשת בבינה מלאכותית כדי ליצור בדיקות יחידה של Java באופן אוטומטי. כלים אחרים, כגון Testim⁶⁷ ו-Applitools⁶⁷, ממנפים למידת מכונה כדי לשפר את אמינות בדיקות ממשק המשתמש ואת זיהוי גרסיה חזותית. יתר על כן, בינה מלאכותית יכולה לחזות אזורים בקוד שסביר להניח שהם מכילים באגים על סמך נתוני commit היסטוריים או מדדי מורכבות קוד⁶⁸, ובכך למקד את המאמץ האנושי במקום בו הוא הכי נחוץ⁶⁹ (Tufano et al., 2020).

עלייתם של מודלים גדולים של שפה (LLMs) כמו ChatGPT ו-Gemini אפשרה עוד יותר עיצוב תוכנה מבוסס שיחה. מעצבים יכולים כעת לתקשר עם סוכני בינה מלאכותית כדי ליצור סיעור מוחות של רעיונות לתכונות, ליצור סיפורי משתמשים, לדמות אינטראקציות של משתמשים או להבהיר אילוצי עיצוב. דבר זה יוצר זרימת עיצוב איטרטיבית וטבעית יותר, שבה מעצבים אנושיים יכולים לבטא כוונה ולקבל הצעות מעשיות בזמן אמת. תהליך יצירה משותף זה מגשר על הפער בין הקונספטואליזציה ליישום, והופך את הבינה המלאכותית לשותף עיצוב דינמי ולא רק לכלי.

ב-DevOps ו-CI/CD pipelines⁷⁰, בינה מלאכותית משפרת את האמינות והביצועים של אספקת תוכנה. מודלים של אנליטיקה חזויה יכולים לזהות אנומליות פריסה, להמליץ על פעולות החזרה למצב אחר ולמטב תצורות בנייה. בינה מלאכותית מסייעת גם בזיהוי דפוסי ניגוד או הצטברות חובות טכניים במהלך תהליך האינטגרציה המתמשך, ומציעה אסטרטגיות תיקון לפני שאלו הופכות לבעיות קריטיות. זה מוביל למערכות

⁶⁶ <https://www.diffblue.com/diffblue-cover/>

⁶⁷ AI from the ground up. <https://www.testim.io/>

The AI-Powered Testing Platform Built for Speed, Scalability and Accuracy. (SOURCE)

⁶⁸ historical commit data or code complexity metrics

⁶⁹ In computer science and data management, a commit is a behavior that marks the end of a transaction and provides Atomicity, Consistency, Isolation, and Durability (ACID) in transactions.

⁷⁰ CI/CD stands for continuous integration and continuous delivery or deployment.

עיצוב אדפטיביות ועמידות יותר שיכולות להתפתח באופן רציף, הכרח בסביבות זריזות ו- DevSecOps⁷¹ (Shahin et al., 2017) [136,133].

למרות יתרונותיה הרבים, שילוב בינה מלאכותית בתוך תוכנה מציב גם אתגרים וחששות אתיים. ראשית, קוד שנוצר על ידי בינה מלאכותית עלול להיות חשוף לפגיעות של אבטחה ואמינות אם לא יאומת כראוי. מכיוון שמודלים כמו קודקס מאומנים במאגרים ציבוריים, הם עשויים לשחזר דפוסים לא מאובטחים או פרקטיקות מוטות הקיימות בנתוני אימון. קיימים גם חששות משפטיים וקניין רוחני סביב ייחוס קוד ותאימות לרישיונות בעת שימוש במודלים גנרטיביים. בנוסף, הסתמכות יתר על כלי בינה מלאכותית עלולה לגרום לניוון מיומנויות בקרב מפתחים אנושיים ולהפחית את אחריות המפתחים אם קוד שנוצר על ידי מכונה מכניס שגיאות (Pearce et al., 2022) [136].

יתר על כן, הסבר ושקיפות נותרים סוגיות קריטיות. מודלים של בינה מלאכותית המשמשים בתוך תוכנה - במיוחד מודלים של למידה עמוקה - הם לעתים קרובות קופסאות שחורות, מה שמקשה על ההבנה מדוע ניתנה המלצה מסוימת לתוכן. אטימות זו יכולה להוביל לחוסר אמון ולעכב אימוץ ביישומים קריטיים לבטיחות כמו שירותי בריאות, ביטחון או פיננסים, שבהם עמידה בתקנים ומעקב הם מאוד חשובים וחיוניים.

במבט קדימה, עתיד עיצוב התוכנה צפוי לכלול מערכות בינה היברידיות, שבהן בינה מלאכותית מגבירה את היצירתיות האנושית במקום להחליף אותה. מחקר מתפתח בתחום הבינה המלאכותית (Human-In-the-Loop) ומערכות נירו-סימבוליות שואף לשלב לוגיקה פורמלית עם מודלים מבוססי למידה, מה שמאפשר כלי עיצוב הניתנים ליותר פירוש ובקרה. בנוסף, בינה מלאכותית יכולה להקל על מערכות תוכנה אדפטיביות הלומדות מהתנהגות המשתמש לאחר הפריסה ומציעות שיפורי עיצוב בזמן אמת - לולאת משוב בין עיצוב, פריסה וחווית משתמש.


לסיכום, אפשר לומר שההשפעה של בינה מלאכותית על תהליכי עיצוב תוכנה היא עמוקה ורב-גונית כאחד. על ידי אוטומציה של משימות שגרתיות, שיפור החלטות בתוך ועיצוב, מתן אפשרות לפיתוח מונחה נתונים וטיפול צורות חדשות של שיתוף פעולה, בינה מלאכותית מחוללת מהפכה באופן שבו תוכנה נוצרת. היא לא רק מאיצה תהליכים וזרימות עבודה קיימות, אלא מגדירה אותן מחדש, מעבירה את תפקידו של מהנדס התוכנה ממקודד למתזמר של כלים חכמים. ככל שטכנולוגיות אלו יתבגרו, תחום עיצוב התוכנה יגלם יותר ויותר את עקרונות האינטליגנציה, הסתגלות ולמידה מתמשכת - מאפיינים בולטים של עידן הבינה המלאכותית.

8.2. כיצד פיתוח תוכנה משתנה – ואיך הוא משפיע על הכישורים הנדרשים

במאמר [85] של חברת McKinsey המחברים כותבים שפיתוח כישורי התוכנה שחברות צריכות על מנת לגדול ולהתפתח פירושו לחשוב במונחים של מיומנויות נדרשות ולא במונחים תפקידים כדי לנווט בתקופה זו של אי ודאות סביב כישורים.

⁷¹ DevSecOps stands for development, security, and operations.

כל חשיבה מחודשת בקשר לכישרון הנדסי צריכה להתחיל בהבנה כיצד בינה מלאכותית מדור ראשון תשפיע על מחזור החיים של פיתוח מוצר (PDLC)⁷². השינויים צפויים להיות משמעותיים וישפיעו על כל שלב במחזור החיים (ראה איור 8.1). המחקר של מקינזי מצביע על כך שלכלים של בינה מלאכותית מדור ראשון יש השפעה חיובית כמעט כפולה על משימות עתירות תוכן (כגון סינתזה של מידע, יצירת תוכן וסיעור מוחות) מאשר על תוכן של משימות קלות (לדוגמה, ויזואליזציה).



איור 8.1-1 - בינה מלאכותית יוצרת משפיעה על כל שלב במחזור חיי פיתוח התוכנה

Source: ChatGPT - The gen AI skills revolution

⁷² product development life cycle (PDLC)

הכישורים שמהנדסי התוכנה צריכים לפתח יתחלקו ככל הנראה לשלושה תחומים:

- סקירה (Review) וחשיבה ביקורתית. אחוז משמעותי מהקוד שנוצר על ידי הדור הנוכחי של כלי בינה מלאכותית דורש תיקון מסוים. ברמה אחת, זה דורש מהמפתחים לעבור מ"עושה" ל"בודק", וזה לא בסיסי כפי שזה נשמע. חלק מהמתכנתים המיומנים אינם בהכרח בודקים טובים. בודקים טובים חייבים להיות מסוגלים להעריך תאימות מבוססת קוד עם מאגרי קוד וארכיטקטורות קיימים, למשל, ולהבין מה נדרש כדי שצוות אחר יוכל לתחזק בקלות את הקוד - כישורים שיש למהנדסים מנוסים יותר לעתים קרובות, אבל עמיתים זוטרים יותר צריכים לבנות. מפתחים יצטרכו לא רק לזהות כפילויות או שגיאות ברורות, אלא להבטיח קוד באיכות גבוהה על ידי פיתוח כישורים מתקדמים כדי לזהות ולטפל בבעיות. מורכב עוד יותר יהיה "הכשרת" כלי בינה מלאכותית יוצרת, שיצטרכו ללמוד תוך כדי עבודה כדי להשתפר. זה ידרוש מהמהנדסים להבין כיצד לתת משוב לכלים ולקבוע אילו סוגי משימות מספקים את ההזדמנות הטובה ביותר לכלי מסוים ללמוד כדי להפיק תוצאות טובות.
- חיבור (Connect). שילוב היכולות של סוכני בינה מלאכותית מרובים יכול לשפר את מהירות פתרון הבעיות ואת איכות הפתרון. ארגונים מסוימים כבר משלבים בינה מלאכותית יוצרת עם מקרי שימוש יישומיים של בינה מלאכותית, כגון שימוש במערכות בינה מלאכותית יישומיות כדי לנתח את ביצועי התוכן שנוצר על ידי בינה מלאכותית יוצרת על ידי זיהוי דפוסים במעורבות המשתמשים, אשר לאחר מכן מוזנים בחזרה למודל. לדוגמה, חברת ביוטכנולוגיה Recursion פיתחה פלטפורמת בינה מלאכותית יוצרת חדשה המאפשרת למדענים גישה למודלים מרובים של למידת מכונה שיכולים לעבד כמויות גדולות של מערכי נתונים ביולוגיים וכימיים קנייניים. מיומנות קריטית שמהנדסים חייבים לפתח היא כיצד לבחור ולשלב יישומים ומודלים של בינה מלאכותית יוצרת (לדוגמה, כיצד מודל אחד עשוי להיות טוב במתן בקרת איכות עבור מודל ספציפי אחר).
- תכן (Design). ככל שטכנולוגיית בינה מלאכותית יוצרת משתלטת על יותר משימות קידוד בסיסיות, מהנדסים צריכים לפתח מערך חדש של "מיומנויות" בעלות ערך גבוה יותר, כגון כתיבת סיפורי משתמשים, פיתוח מסגרות קוד (לדוגמה, ספריות קוד, תוכניות תמיכה), הבנת תוצאות עסקיות וצפי כוונת המשתמש. תקשורת היא מיומנות קריטית ומתפתחת, והיא נחוצה כדי להבטיח שמהנדסים יוכלו לתקשר בצורה יעילה יותר עם צוותים, מנהיגים, עמיתים ולקוחות.

8.3. מגמות עתידיות

מגמות מתפתחות בתחום הבינה המלאכותית מעצבות מחדש את פיתוח התוכנה, ולכן מנהיגי ומובילי טכנולוגיה חייבים להישאר מעודכנים וגמישים. למידת מכונה מתפתחת במהירות, ומביאה דרכים טובות יותר לניתוח נתונים וליצירת תוכנה חכמה יותר. בינה מלאכותית גם משפרת את מחשוב הענן, ומשפרת את האופן שבו אנו מנהלים ומעבדים נתונים. במחשוב קצה, בינה מלאכותית מאיצה את עיבוד הנתונים, וזהו יתרון גדול לדברים כמו מכשירים המחוברים לרשת האינטרנט IoT.

יש גם דגש גובר על בינה מלאכותית אתית. נושאים כמו פרטיות, הטיה ופעולות ברורות מקבלים יותר תשומת לב, מה שמדגיש את הצורך בסטנדרטים אתיים בפיתוח בינה מלאכותית. שילוב בינה מלאכותית בפיתוח תוכנה מציג סוגיות אתיות ותאימות חשובות. חיוני שמערכות בינה מלאכותית יפותחו וישמשו בהתאם לסטנדרטים ותקנות אתיים. משמעות הדבר היא יצירת אלגוריתמים של בינה מלאכותית שהם הוגנים, מכבדים את פרטיות המשתמש ושקופים באופן פעולתם.

בינה מלאכותית משנה גם את אופן ביצוע הקידוד, עם כלים חדשים לכתיבת קוד אוטומטית ואופטימיזציה שהופכים את עבודת המפתחים ליעילה יותר.

באבטחת סייבר, אלגוריתמים של בינה מלאכותית משמשים יותר לאיתור מהיר של איומים ותגובה אליהם. בינה מלאכותית גם מתאימה תוכנה להעדפות המשתמש באמצעות ניתוח נתונים מעמיק כדי לשפר את האופן שבו משתמשים מקיימים אינטראקציה עם התוכנה ותחשורתיה.

עבור מהנדסים שנמנים על מובילי ומנהיגי טכנולוגיה, שמירה על קצב מגמות בינה מלאכותית אלו חיונית להכנת הארגונים שלהם לעתיד. משמעות הדבר היא אימוץ טכנולוגיות חדשות וטיפול תרבות המתמקדת בבינה מלאכותית המעריכה למידה וחדשנות מתמשכות.

9. השפעת הבינה המלאכותית על תחום הנדסת האלקטרוניקה

בינה מלאכותית זרזה טרנספורמציה עמוקה בהנדסת אלקטרוניקה, ועיצבה מחדש באופן מהותי את האופן שבו מעגלים מתוכננים, מדומים, מותאמים, מיוצרים, נבדקים ואפילו מנוהלים, ומציעה אופקים חדשים של ביצועים, יעילות, חדשנות ואינטגרציה בין-תחומית [39,38,37,36,35]. שילוב הבינה המלאכותית בכלי אוטומציה של תכן אלקטרוני (EDA)⁷³ מאפשר כעת יצירת סכמות ואופטימיזציה של פריסה שהיו כמעט בלתי אפשריות - או גוזלות זמן רב מדי - עבור מהנדסים לבצע באופן ידני. באמצעות אלגוריתמים של למידה עמוקה ולמידה מחזקת שאומנו על ספריות נרחבות של סכמות קיימות, מעגלים מודפסים ואילווצי ייצור, כלי תכן המופעלים על ידי בינה מלאכותית יכולים להציע דפוסי בחירה, מיקום וניתוב אופטימליים של רכיבים אשר ממזערים את צריכת החשמל, משפרים את שלמות האות ומפחיתים בזבז באמצעות מידול תרמי מערכות בינה מלאכותית אלו הופכות מטלות חוזרות ונשנות לאוטומטיות - כגון יצירת סכמות ראשוניות, ניתוח איטרציות פריסה מרובות ובדיקת הפרות של כללי תכן - מה שמשחרר מהנדסים אנושיים לעסוק במשימות יצירתיות ובין-תחומיות ברמה גבוהה יותר ומאיצים משמעותית את זמן ההגעה לשוק. בכלים כמו Cadence Virtuoso⁷⁴, בינה מלאכותית מטפלת בכל דבר, החל מפרשנות אילווצים, סינתזה ראשונית של רשימות רשת, יצירת פריסה המכבדת את שלמות האות/הספק, ועד לבדיקת פריסה לעומת סכמטיקה (LVS)⁷⁵ ובדיקת כללי תכן (DRC)⁷⁶, סימון עומסי ניתוב והצעת תיקונים לפני ייצור. טכניקות בינה מלאכותית גנרטיביות מרחיבות עוד יותר את המהפכה הזו: על ידי בחינת אלפי תצורות תכן פוטנציאליות והערכתן מול מטרות מרובות מטרות - כגון מזעור אורך העקיבה, אופטימיזציה של מהירות השעון, הפחתת EMI והגבלת יצירת חום - בינה מלאכותית יכולה לשפר באופן ניכר את היעילות, ולהשיג רווחי ביצועים או הספק מדווחים של 10-15% לעומת עיצובים מסורתיים.

בסימולציה ואימות של מעגלים, בינה מלאכותית מאפשרת קביעת סדרי עדיפויות חכמים של תנאי בדיקה. במקום סימולציות בכוח גס בכל תרחישי המתח, הטמפרטורה והעומס, טכניקות למידת מכונה מכוונות את המיקוד למקרי קצה בסיכון גבוה ולגילוי אנומליות מוקדם, מה שמאיץ את מחזורי האימות עד 30% ומשפר את אמינות התכן הכוללת. גילוי תקלות וניתוח כשל משופרים על ידי בינה מלאכותית - באמצעות זיהוי תבניות בנתוני סימולציה או קלט חיישנים מהעולם האמיתי - עוזרים למהנדסים לזהות במהירות את גורמי השורש של הכשל ולהמליץ על פעולות מתקנות, תוך צמצום מאמצי ניפוי שגיאות והפחתת זמן השבתה. יישומי פתרון בעיות אוטומטיים יכולים לפרש מגמות ביומן שגיאות ונתוני התנהגות מעגל כדי לאתר במדויק רכיבים פגומים - תוך מתן תפקיד כמהנדס שני וירטואלי - בעוד שמודלים ניבויים המונעים על ידי בינה מלאכותית מדגישים בעיות אמינות סמויות לפני שהן מתעוררות.

⁷³ electronic design automation (EDA)

⁷⁴ Cadence Virtuoso is a comprehensive Electronic Design Automation (EDA) tool suite used for designing and verifying analog, mixed-signal, and RF integrated circuits.

https://www.cadence.com/en_US/home/tools/custom-ic-analog-rf-design/layout-design/virtuoso-layout-suite.html

⁷⁵ layout-versus-schematic (LVS)

⁷⁶ design-rule checking (DRC)

בייצור ובקרת איכות, מערכות ראייה ממוחשבת המונעות על ידי בינה מלאכותית הפכו להכרחיות – והן משמשות לגילוי פגמי הלחמה זעירים, חוסר יישור, סדקים זעירים במעגלים מודפסים ואנומליות עדינות אחרות. מערכות אלו מבטיחות איכות בדיקה גבוהה באופן עקבי תוך האצה דרמטית של קווי הייצור themetamyths.com. בקנה מידה גדול יותר, בינה מלאכותית תומכת בפרדיגמות של מפעלים חכמים: על ידי ניטור ביצועי מכונה וקורלציה של נתוני חיישנים חיים עם אירועי כשל היסטוריים, מודלי למידה חישובית חוזים פגיעה בצידוד, ומאפשרים משטרי תחזוקה חזויים המפחיתים זמני השבתה יקרים ובלתי מתוכננים ומאפשרים הקצאת משאבים אופטימלית. מעבר למתקני ייצור, בינה מלאכותית מוכיחה את עצמה כמרכזית בשרשראות אספקה של אלקטרוניקה, ומנתחת נתונים חוצי מודלים – מיומני רכש ועד תחזיות לוגיסטיקה וביקוש – כדי לצפות שיבושים, לייעל את רמות המלאי ולקצר את זמני האספקה, ובסופו של דבר משפרים את החוסן ומפחיתים עלויות.

בינה מלאכותית מאפשרת גם גילוי ויישום של חומרים אלקטרוניים וארכיטקטורות התקנים חדשים. באלקטרוניקה של הספק ומערכות בקרה, אלגוריתמי למידה אלקטרונית (ML) ממטבים טופולוגיות של ממיר, הגדרות בקר ופרמטרי רכיבים כדי לעמוד ביעדי ביצועים ויעילות מחמירים, כפי שמפורט בסקירות אחרונות [בפוטוניקה והנדסה נורומורפית (neuromorphic engineering)]⁷⁷, בינה מלאכותית תומכת בתכן של מעגלים משולבים נורומורפיים ופוטוניים – קריטיים לשבבי רשת נורונים מהירים מהדור הבא – ומסייעת בהפחתת ההיחייב וצריכת החשמל על ידי הנחיית גיאומטריה של התקנים ובחירות טופולוגיה [באופן דומה, טכניקות מאינפורמטיקה של חומרים וגילוי מואץ של בינה מלאכותית מנבאות תרכובות וחומרים מרוכבים חדשים – למשל, זיהוי חומרים המאריכים את חיי הסוללה או משפרים את הביצועים התרמיים – ומגשרים בין אלקטרוניקה למדע החומרים.

יתר על כן, בינה מלאכותית מעצבת מחדש את תפקידם של מהנדסי אלקטרוניקה באקדמיה ובתעשייה על ידי דרישה למערכי מיומנויות חדשים ומאפשרת חדשנות שיתופית. מהנדסים חייבים כעת ללמוד לשלב כלי בינה מלאכותית, לפרש פלטי מודלים של קופסה שחורה ולאמת עיצובים שנוצרו על ידי בינה מלאכותית מול אילוצים פיזיים ותקני בטיחות. תוכניות חינוך ופיתוח מקצועי כבר מתפתחות כדי להדגיש אוריינות בינה מלאכותית, חשיבה עיצובית מונעת נתונים ושיתוף פעולה בין-תחומי בין תחומי חומרה, תוכנה, בקורות ומדעי הנתונים. מבחינה אתית, הטמעת בינה מלאכותית בתחומים קריטיים מעלה חששות לגבי שקיפות, הטיה, אחריות אלגוריתמית ומחסומי הסמכה – במיוחד בתעשיות קריטיות לבטיחות כמו רכב, תעופה וחלל ובריאות – הדורשים מהנדסים לאזן בין יכולות מתקדמות לבין הסבר, תאימות ואמינות.

עם זאת, כוחה של בינה מלאכותית בהנדסת אלקטרוניקה אינו נטול מגבלות. עלויות התחלתיות גבוהות, מורכבות טכנית, מחסור בנתונים ותקורות חישוביות צוטטו כמחסומי אימוץ – במיוחד עבור עסקים קטנים ובינוניים חסרי תשתית רבת נתונים (ביג דאטה) או מומחיות פנימית בבינה מלאכותית. בכיול חיישנים קריטי למשימה או בחזיתות אנלוגיות של אותות מעורבים, מודלים של למידת מכונה הסתברותית עשויים להיות פחות מדויקים או ניתנים לפירוש ממודלים אנליטיים דטרמיניסטיים, מה שמציג אתגרים כאשר נדרשת אמינות מוחלטת. התגברות על אתגרים אלה תדרוש אסטרטגיות תכן היברידיות המשלבות בינה מלאכותית

⁷⁷ Neuromorphic engineering is a multidisciplinary field that creates artificial neural systems inspired by the structure and function of the human brain

מונעת נתונים עם שיטות מסורתיות מבוססות פיזיקה, תוך אימוץ ארכיטקטורות מודל שקופות, נתוני אימון חזקים ופיקוח אנושי בלולאה.

למרות הסתייגויות אלו, המומנטום לעבר הנדסת אלקטרוניקה משופרת מבוססת בינה מלאכותית הוא בלתי ניתן לעצירה. כלי עיצוב גנרטיביים כמו SnapMagic Copilot ממחישים כיצד מהנדסים יכולים להעביר משימות מייגעות ברמה נמוכה לבינה מלאכותית, מה שמאפשר איטרציות מהירות ועיצובים מותאמים אישית אופטימליים במיוחד [39]. מפעלים חכמים המופעלים על ידי NVIDIA Metropolis⁷⁸ [40] ופלטפורמות דומות הופכים לנורמה, בעוד שבינה מלאכותית משובצת בקצה האלקטרוניקה של IoT ובמערכות אוטונומיות מאפשרת חישה, עיבוד ואדפטציה בזמן אמת ובעלי ההשייה נמוכה techexplorations.com. מבחינה אקדמית, הופעתם של מחשוב נירומורפי, מאיצי בינה מלאכותית פוטוניים ומסגרות אמינות מבוססות למידה אלקטרונית מאותתת על התכנסות של אלקטרוניקה, בינה מלאכותית ומדעי החומרים - ובו פתח לעידן חדש של מערכות אלקטרוניקה חכמות, אדפטיביות וברות קיימא באמת.

לסיכום, בינה מלאכותית כבר אינה שיפור אופציונלי - היא למעשה הופכת להיות גורם חיוני לחדשנות בהנדסת אלקטרוניקה, המשפיע על כל שלב במחזור חיי המוצר, מהרעיון ועד ליציאה משימוש. היא משפרת את הביצועים, האמינות והתשואה תוך הפחתת עלויות, זמן פיתוח והשפעה סביבתית. הבינה המלאכותית, הניצבת בפני אתגרים חדשים בתחומי האתיקה, חינוך כוח אדם, הסבר ותאימות לתקנות, גם מעצימה מהנדסים לפעול ברמת הפשטה גבוהה יותר ולחקור מרחבי תכן לא מוכרים. ככל שהבינה המלאכותית ממשיכה את מסלולה, תחום האלקטרוניקה עומד להתפתח לתחום משולב ואינטליגנטי שמגדיר מחדש הן את מה שאנו בונים והן את האופן שבו אנו בונים אותו, עם מתודולוגיות יצירתיות, אימות ממוקד נתונים ואוטונומיה בליבתו.

⁷⁸ NVIDIA Metropolis

<https://www.nvidia.com/en-eu/autonomous-machines/intelligent-video-analytics-platform/>

10. השפעת הבינה המלאכותית על תחום הנדסת

אווירונאוטיקה

בינה מלאכותית (AI) מחוללת מהפכה בתחום ההנדסה האווירונאוטית על ידי שינוי האופן שבו כלי טיס מתוכננים, מיוצרים, מופעלים ומתוחזקים, ובפועל מבשרת עידן חדש של אוטונומיה, יעילות ובטיחות במערכות תעופה וחלל [41]. החל מאופטימיזציה של תכן אווירודינמי דרך אלגוריתמים של למידת מכונה ועד לאפשרות תחזוקה חזויה באמצעות ניתוח נתוני חיישנים, בינה מלאכותית הופכת הכרחית בהתמודדות עם המורכבות הגוברת של מערכות תעופה מודרניות. בשלב התכן, כלי אופטימיזציה המופעלים על ידי בינה מלאכותית נמצאים כיום בשימוש נרחב בדינמיקת נוזלים חישובית (CFD) כדי להפחית גרר, לשפר את העילוי ולשפר את יעילות הדלק [116]. כלים אלה משתמשים בלמידה עמוקה וברשתות עצביות כדי ללמוד ממערכי נתונים עצומים של סימולציות אווירודינמיות, ובכך להפחית את הזמן וכוח החישוב הנדרשים לאיטרציות תכן. לדוגמה, חוקרים בנאס"א השתמשו בלמידת חיזוק עמוקה כדי ליעל מבני כנף ומשטחי בקרה עבור כלי טיס אוטונומיים [45]. באופן דומה, תכן גנרטיבי - גישה מונחית בינה מלאכותית - מאפשר למהנדסים להזין פרמטרי תכן ולקבל אלפי חלופות תכן המותאמות לביצועים, שימוש בחומרים ושלמות מבנית. פרדיגמה זו לא רק מאיצה את מחזור התכן, אלא גם פותחת תצורות חדשות שעשויות להיות סותרות את הגישות ההנדסיות המסורתיות [42].

השפעת הבינה המלאכותית משפיעה גם על ייצור מטוסים, כאשר רובוטיקה בשילוב עם ראייה ממוחשבת ולמידת מכונה מאפשרת הרכבה מדויקת, בקרת איכות וזיהוי פגמים בחומרים מרוכבים. בואינג ואיירבוס השקיעו רבות במערכות רובוטיות מבוססות בינה מלאכותית לקידוח, צביעה ובדיקת שלדות מטוסים, מה שמפחית משמעותית טעויות אנוש ומשפר את הפרודוקטיביות [108]. ייצור מרובד (הדפסה תלת-ממדית) משופר גם הוא באמצעות אלגוריתמים של בינה מלאכותית אשר מנטרים את איכות ההדפסה בזמן אמת ומתאימים פרמטרים באופן דינמי כדי להבטיח אמינות מבנית של רכיבי התעופה והחלל. בתחום מערכות ההנעה, בינה מלאכותית משמשת לשיפור התכן והבקרה של מנועי סילון, כולל פיתוח של תאומים דיגיטליים - העתקים וירטואליים של מנועים המדמים ביצועים, בלאי וקרעים בזמן אמת. תאומים דיגיטליים אלה, המונעים על ידי בינה מלאכותית ונתוני חיישנים בזמן אמת, מאפשרים למהנדסים לחזות כשלים לפני שהם מתרחשים, מה שמוביל לתחזוקה פרואקטיבית ויזומה ולהפחתת זמן השבתה [34]. תחזוקה חזויה, בפרט, מייצגת את אחד היישומים הטכנולוגיים ביותר של בינה מלאכותית בהנדסת אווירונאוטיקה. באמצעות מודלים של בינה מלאכותית המאומנים על נתוני טיסה ותחזוקה, חברות תעופה יכולות לחזות נזקי רכיבים ולתזמן תחזוקה רק בעת הצורך, ובכך להאריך את תוחלת החיים של הרכיבים ולהפחית את עלויות התפעול [83].

תאום דיגיטלי הוא העתק דיגיטלי של אובייקט פיזי, אדם, מערכת או תהליך, הממוקם בגרסה דיגיטלית של סביבתו. תאומים דיגיטליים יכולים לעזור לסוגים רבים של ארגונים לדמות מצבים אמיתיים ואת תוצאותיהם, ובסופו של דבר לאפשר להם לקבל החלטות טובות יותר.

פעולות טיסה ואוטונומיה הן תחומים קריטיים נוספים שבהם בינה מלאכותית מעצבת מחדש את הנדסת האווירונאוטיקה. מטוסים מודרניים מצוידים במערכות בקרת טיסה אוטונומיות יותר ויותר המשתמשות בבינה מלאכותית כדי לפרש נתונים מחיישנים, להתאים משטחי בקרה ולהגיב לשינויים סביבתיים. מערכות טייס אוטומטי המופעלות על ידי בינה מלאכותית חורגות מעבר לתכנות מסורתי מבוסס כללים על ידי למידה מנתוני טיסה היסטוריים והתאמה לתרחישים בלתי צפויים כגון פגיעות ציפורים, כשלי מנוע או שינויי מזג אוויר פתאומיים. פרויקטים כמו "ATTOL" (Autonomous Taxi, Take-Off, and Landing) של איירבוס הדגימו את היתכנותן של פעולות טיסה אוטונומיות לחלוטין באמצעות מערכות ראייה ממוחשבת וקבלת החלטות מבוססות בינה מלאכותית [149]. בנוסף, שילוב בינה מלאכותית בניהול תנועה אווירית מייעל את אופטימיזציית נתיבי הטיסה, מפחית עיכובים ומשפר את הבטיחות על ידי חיזוי התנגשויות והצעת פתרונות בזמן אמת [44,43]. ביישומי תעופה וחלל צבאיים, בינה מלאכותית משולבת בכלי טיס בלתי מאוישים (UAVs)⁷⁹ ובמטוסי קרב מהדור הבא למשימות כגון זיהוי מטרות אוטונומי, גילוי איומים ומודיעין נחיליים. תוכנית סקייבורג של חיל האוויר האמריקאי מדגימה את השימוש ברחפנים מבוססי בינה מלאכותית הפועלים בשיתוף פעולה עם טייסים אנושיים בתרחישי קרב, ויוצרים מערכות צוות מאוישות-ובלתי מאוישות המשנות באופן דרמטי את הדינמיקה הטקטית.

יתר על כן, בינה מלאכותית מעצבת מחדש את החינוך וההכשרה בתחום התעופה והחלל באמצעות פיתוח מערכות הדרכה חכמות וסביבות סימולציה שמתארות תרחישים שונים. סימולטורים מבוססי בינה מלאכותית מספקים לטייסים ולמהנדסים חוויות הדרכה מציאותיות ואדפטיביות, המאפשרות להם לתרגל תרחישים מורכבים ולקבל משוב מותאם אישית. כלים אלה לא רק משפרים את תוצאות הלמידה אלא גם מפחיתים את עלויות ההדרכה ומשפרים את המוכנות לבטיחות. עיבוד שפה טבעית (NLP)⁸⁰, תת-תחום של בינה מלאכותית, מאפשר גם אינטראקציות אינטואיטיביות יותר בין בני אדם למכונות בתעופה, כגון ממשקי תא טייס הנשלטים קולית ותקשורת אווירית אוטומטית, מה שמפחית את עומס העבודה של הטייסים ואת הסיכון לתקשורת לקויה. במקביל, בינה מלאכותית תומכת בהתפתחות התעופה בת קיימא על ידי אופטימיזציה של נתיבי טיסה כדי להפחית את צריכת הדלק והפליטות, ועל ידי הקלת תכן של מטוסים היברידיים-חשמליים ומימן באמצעות ניסויים מונעי סימולציה.

שילוב הבינה המלאכותית בהנדסת אווירונאוטיקה אינו מגיע ללא אתגרים. דאגה מרכזית אחת היא הסמכה ופיקוח רגולטורי על מערכות מבוססות בינה מלאכותית, במיוחד ביישומים קריטיים לבטיחות כמו טיסה אוטונומית ותחזוקה. שלא כמו מערכות מסורתיות בעלות התנהגות דטרמיניסטית, מערכות בינה מלאכותית הן לעתים קרובות אטומות ("קופסאות שחורות"), מה שמקשה על הסבר תהליכי קבלת ההחלטות שלהן ואישור בטיחותן. חוקרים וגופים רגולטוריים, כולל ה-FAA וה-EASA, עובדים על מסגרות להסבר, שקיפות ותיקוף של מערכות בינה מלאכותית בתעופה וחלל [43]. אבטחת סייבר היא נושא קריטי נוסף, שכן קישוריות מוגברת ותלות בתוכנה מציגות פגיעויות שניתן לנצל כדי לשבש מערכות מטוסים. הבטחת החוסן והעמידות של אלגוריתמי בינה מלאכותית כנגד התקפות עוינות ותנאי קלט בלתי צפויים היא בעלת חשיבות עליונה לשמירה על אמון בפתרונות תעופה וחלל המונעים על ידי בינה מלאכותית.

⁷⁹ unmanned aerial vehicles (UAVs)

⁸⁰ Natural language processing (NLP)

אתגר דחוף נוסף הוא שילוב מערכות בינה מלאכותית עם תשתיות אוויוניקה ומערכות אוויוניקה מדור קודם. מטוסים רבים עדיין מסתמכים על מערכות חומרה ותוכנה שפותחו לפני עשרות שנים, מה שיוצר בעיות תאימות עם מודולים מודרניים מבוססי בינה מלאכותית. שדרוג מערכות אלו הוא לעתים קרובות יקר ומורכב, ודורש גישות חדשניות לאינטגרציה היברידית ותאימות לאחר. בנוסף, יש לאמן מודלים של בינה מלאכותית על מערכי נתונים מגוונים ואיכותיים, שלעתים קרובות הם קנייניים או לא שלמים. שיתופי פעולה בין חברות תעופה וחלל, מוסדות מחקר וסוכנויות ממשלתיות חיוניים לבניית מערכי נתונים ותקנים משותפים שיכולים להאיץ את אימוץ הבינה המלאכותית ברחבי התעשייה. שיקולים אתיים סביב אוטונומיה, אחריות ופיקוח אנושי צוברים גם הם בולטות, במיוחד כאשר בינה מלאכותית מתחילה לקבל החלטות בעלות סיכון גבוה במערכות אוטונומיות וביישומים צבאיים.

מבחינת השלכות על כוח העבודה, בינה מלאכותית מעצבת מחדש את תפקידם של מהנדסי אווירונאוטיקה על ידי העברת המיקוד מתכן וניתוח ידניים לחשיבה ברמת המערכת, ניתוח נתונים ושיתוף פעולה בין-תחומי. מהנדסים זקוקים כיום למיומנות בלמידת מכונה, תכנות ואינטגרציה של מערכות בנוסף ליסודות המסורתיים בתחום התעופה וחלל. אוניברסיטאות וגופים מקצועיים מעדכנים תוכניות לימודים כדי לכלול בינה מלאכותית, מדעי הנתונים ורובוטיקה כמרכיבים מרכזיים בחינוך להנדסת אווירונאוטיקה וחלל [78]. ככל שכלי בינה מלאכותית הופכים משולבים יותר בתהליך העבודה ההנדסי, מהנדסים פועלים יותר כמתזמרים - אוצרים, מפקחים ומאמתים תפוקות המונעות על ידי בינה מלאכותית במקום לבצע כל משימה באופן ידני [79].

לסיכום, בינה מלאכותית משנה באופן עמוק את התחום של הנדסת אווירונאוטיקה על ידי שיפור חדשנות עיצובית ותכנונית, אופטימיזציה של פעולות, מתן אפשרות לאוטונומיה ושיפור הבטיחות. היא מטפחת מעבר למערכות אווירונאוטיקה חכמות יותר, בנות קיימא ועמידות יותר. עם זאת, שילוב מוצלח של בינה מלאכותית דורש התמודדות עם אתגרים טכניים, רגולטוריים, אתיים וחינוכיים באמצעות גישות שיתופיות ורב-תחומיות. עתיד הנדסת אווירונאוטיקה יוגדר ככל הנראה על ידי מיזוג חלק של מומחיות אנושית ובינה מלאכותית, שיוביל לפריצות דרך שהיו בעבר מעבר לדמיון.

11. בינה מלאכותית בתחומי הנדסה חוצי דיסציפלינות

11.1. השפעת בינה מלאכותית על נושא הסימולציה בהנדסה

סקירה כללית

בינה מלאכותית (AI) מחוללת מהפכה בסימולציה בהנדסה על ידי שיפור דרמטי של המהירות, הדיוק וקבלת ההחלטות בתהליכי תכן, בדיקה ואופטימיזציה. שיטות סימולציה מסורתיות, למרות שהן חזקות, הן לרוב יקרות מבחינה חישובית ומוגבלות על ידי מודלים סטטיים. בינה מלאכותית מציגה גישות מונחות נתונים כגון מודלים חלופיים, למידת מכונה ומידול מסדר מופחת כדי לחקות סימולציות באיכות גבוהה בעלות חישובית נמוכה משמעותית.

אחת התרומות המרכזיות של בינה מלאכותית היא אוטומציה של הגדרת סימולציה, יצירת רשת וניתוח גיאומטריה - משימות שבעבר דרשו קלט אנושי ממנהנדס מומחה. דבר זה הופך את הסימולציה לנגישה יותר ומהירה יותר לפריסה. בינה מלאכותית גם מאפשרת הטמעת נתונים בזמן אמת, תומכת בתחזוקה ניבויית ואופטימיזציה תפעולית במערכות כמו טורבינות ותשתיות חכמות באמצעות תאומים דיגיטליים. יתר על כן, בינה מלאכותית מצטיינת בטיפול בחוסר ודאות באמצעות מודלים הסתברותיים ומשפרת תהליכי תכן באמצעות טכניקות פתרון בעיות ואופטימיזציה הפוכה.

בתרחישים מורכבים כמו מולטיפיזיקה (Multiphysics)⁸¹ והנדסת חומרים, בינה מלאכותית משפרת את דיוק המידול ומאפשרת תובנות מהירות יותר לגבי התנהגויות תלויות זו בזו. יוזמות כמו פרויקט גנום החומרים ופיתוחים ברשתות עצביות מבוססות פיזיקה (PINN)⁸² מראות כיצד בינה מלאכותית מאיצה חדשנות בתכן חומרים ובמידול פיזי. כלי תכן גנרטיביים ובינה מלאכותית מוסברת מטפחים עוד יותר שיתוף פעולה יצירתי ואמין בין בני אדם למכונות.

למרות אתגרים הקשורים לאיכות הנתונים, יכולת הפרשנות והשילוב עם כלים מדור קודם, בינה מלאכותית הופכת בהתמדה לחלק בלתי נפרד מזרימות עבודה של סימולציה. ההתכנסות של בינה מלאכותית וסימולציה מבטיחה להפוך את ההנדסה לתחום מהיר, חכם ואדפטיבי (מסתגל) יותר, המאפשר התקדמות חסרת תקדים בפיתוח מוצרים, הערכת סיכונים ואופטימיזציה של מערכות.

סקירה מפורטת

בינה מלאכותית (AI) צצה ככוח משנה עולם בתחום ההנדסה, במיוחד בתחום הסימולציה, שם היא מגדירה מחדש באופן מהותי את האופן שבו מהנדסים מתכננים, בודקים וממטבים מערכות מורכבות [52]. סימולציה

⁸¹ Multiphysics refers to the simultaneous simulation of multiple, interacting physical phenomena in a system, such as fluid flow, heat transfer, structural mechanics, and electromagnetics. It is a computational approach used in engineering and science to model and analyze complex systems where different physics are intertwined and influence each other.

⁸² physics-informed neural networks (PINNs)

ממלאת תפקיד קריטי בהנדסה המודרנית בכך שהיא מאפשרת ניסויים וירטואליים, חיזוי ביצועים וניתוח כשל ללא הזמן וההוצאות הכרוכים בבניית אב טיפוס פיזי. באופן מסורתי, סימולציות היו אינטנסיביות מבחינה חישובית ומגבלות על ידי דיוק של מודלים מתמטיים והנחות אנושיות. עם זאת, בינה מלאכותית משבשת פרדיגמה זו על ידי הצגת מתודולוגיות חכמות, אדפטיביות ומונעות נתונים המשפרות את הנאמנות, המהירות, המדרגיות והתובנות של סימולציות הנדסיות [53]. בין אם בתחום התעופה והחלל, הרכב, האזרחי, הביו-רפואי או הנדסת חומרים, סימולציה מונעת בינה מלאכותית מחוללת מהפכה באופן שבו מהנדסים ניגשים לפתרון בעיות, איטרציות עיצוב וקבלת החלטות.

אחת התרומות המשמעותיות ביותר של בינה מלאכותית לסימולציות הנדסיות טמונה ביכולתה להפחית עלויות חישוביות ולהאיץ את הניתוח באמצעות מודלים חלופיים ומידול מסדר מצומצם (ROM)⁸³. אלגוריתמים של למידת מכונה (ML), ובמיוחד רשתות עצביות, ניתנים לאימון על מערכי נתונים שנוצרו מסימולציות באיכות גבוהה (למשל, ניתוח אלמנטים סופיים או דינמיקת נוזלים חישובית) ולאחר מכן משתמשים בהם כדי לחקות סימולציות אלו עם זמני ריצה קצרים באופן דרמטי [54]. מודלים חלופיים מבוססי בינה מלאכותית אלה שומרים על דיוק גבוה תוך שהם מהירים יותר בסדרי גודל, מה שמאפשר חיזוי ואופטימיזציה בזמן אמת בהקשרים כמו אווירודינמיקה של מטוסים, העברת חום או ניתוח מאמצים מכניים. לדוגמה, נאס"א פיתחה מודלים של למידה עמוקה כדי לחזות מקדמים אווירודינמיים בדיוק דומה למודלים מסורתיים של CFD (דינמיקת נוזלים חישובית) אך בחלקיק מהעלות, מה שמאפשר חקר חלל מהיר של עיצוב עבור גיאומטריות חדשות של מטוסים.

תרומה קריטית נוספת של בינה מלאכותית לסימולציה הנדסית היא אוטומציה חכמה של יצירת מודלים, יצירת רשת (meshing) והגדרה, אשר באופן מסורתי דרשו התערבות אנושית מקצועית [56]. על ידי יישום עיבוד שפה טבעית (NLP), זיהוי תבניות וראייה ממוחשבת, כלי בינה מלאכותית יכולים כעת לפרש מודלים של CAD או מפרטים טכניים וליצור באופן אוטומטי גיאומטריות מוכנות לסימולציה [156,157,158]. אלגוריתמי רשת (meshing) המונעים על ידי בינה מלאכותית יכולים להתאים באופן דינמי את רזולוציית הרשת על סמך אזורי מאמץ צפויים או דפוסי זרימת נוזלים, ובכך לשפר את דיוק הסימולציה מבלי לנפח את דרישות החישוב. אוטומציה זו מפחיתה משמעותית את זמן ההתקנה עבור מהנדסים ומאפשרת דמוקרטיזציה של הגישה ליכולות סימולציה, מה שהופך אותן לזמינות גם לאנשים שאינם מומחים [65].

בינה מלאכותית גם משפרת הטמעת נתונים וסימולציה בזמן אמת, במיוחד במערכות סייבר-פיזיקליות ותאומים דיגיטליים. בתעשיות כמו ייצור, תשתיות אזרחיות ורכב, חיישנים פיזיים אוספים באופן רציף נתונים על ביצועי המערכת, אשר לאחר מכן מוזנים למודלי סימולציה משופרים על ידי בינה מלאכותית המתעדכנים בזמן אמת. שילוב זה מאפשר תחזוקה חזויה, זיהוי תקלות ואופטימיזציה של ביצועים (). לדוגמה, סימנס משתמשת בתאומים דיגיטליים משופרים על ידי בינה מלאכותית כדי לדמות ולחזות את התנהגות התפעול של טורבינות גז בזמן אמת, מה שמאפשר תחזוקה פרואקטיבית ושיפור היעילות [57]. באופן דומה, בבניינים חכמים, בינה מלאכותית משלבת נתוני חיישני IoT עם מודלי סימולציה כדי לנהל את צריכת האנרגיה באופן דינמי, לחזות כשלים בצידוד ולהבטיח נוחות לדיירים.

⁸³ surrogate modeling and reduced-order modeling (ROM)

יתרון עיקרי של בינה מלאכותית בסימולציה הוא יכולתה להתמודד עם אי-ודאות ושונות בצורה טובה יותר בהשוואה למודלים דטרמיניסטיים מסורתיים. מערכות הנדסיות פועלות לעתים קרובות בתנאים לא ודאיים - החל מחוסר עקביות מהותי ותנאי גבול משתנים ועד רעש סביבתי ושגיאות חיישנים. מודלים של בינה מלאכותית, במיוחד אלו המבוססים על הנמקה הסתברותית (למשל, רשתות עצביות בייסיאניות)⁸⁴, יכולים למדל את אי-הוודאות הזו במפורש, ולספק למהנדסים מרווחי סמך במקום תחזיות המסתמכות על נקודה אחת [155]. דבר זה הוא קריטי בתחומים רגישים לסיכון כמו ניטור בריאות מבנית או פיתוח מכשירים ביו-רפואיים, שבהם הבנת טווח התוצאות האפשריות חיונית לבטיחות ואמינות.

בנוסף לחיזוי תוצאות, בינה מלאכותית מצטיינת בפתרון בעיות הפוך ואופטימיזציה, ועוזרת למהנדסים לקבוע פרמטרי תכן אופטימליים על סמך קריטריונים לביצועים רצויים. באופן מסורתי, הדבר דורש הרצת אלפי איטרציות סימולציה בתכן ניסויים (DOE)⁸⁵ או בשגרות אופטימיזציה מרובות-מטרות. אלגוריתמים של בינה מלאכותית, במיוחד למידת חיזוק ואלגוריתמים אבולוציוניים, יכולים לנווט במרחבי תכן מורכבים ובעלי ממדים רבים אלה בצורה יעילה יותר. לדוגמה, בתעשיית הרכב, בינה מלאכותית משמשת לאופטימיזציה של עמידות כלי רכב להתרסקות על ידי התאמת רכיבים מבניים באופן איטרטיבי בסימולציית התרסקות דיגיטלית עד שהמודל עומד בדרישות הבטיחות והעלות [60,5859] באופן דומה, בהנדסת מבנים, מודלים של בינה מלאכותית מסייעים באופטימיזציה של מסגרות נושאות עומס על ידי ניבוי התפלגויות החומרים והגיאוטריות הטובות ביותר.

סימולציה רב-פיזיקלית, הכוללת צימוד של תופעות פיזיקליות שונות כגון אינטראקציות תרמיות, מכניות, אלקטרומגנטיות ונוזליות, מציבה אתגרים מיוחדים לשיטות סימולציה מסורתיות עקב מורכבות פתרון משוואות דיפרנציאליות חלקיות תלויות זו בזו. מודלים של בינה מלאכותית מסוגלים יותר ויותר ללמוד את הצימודים המורכבים בין תחומים פיזיקליים, ומציעים פתרונות מקורבים מהירים יותר, ובמקרים רבים מדויקים מספיק לקבלת החלטות הנדסיות [63, 64, 72]. הדבר ניכר בתחומים כמו הנדסה ביו-רפואית, שבהם סימולציות המונעות על ידי בינה מלאכותית יכולות למדל את האינטראקציה בין זרימת הדם לעיוות דופן העורקים בצורה יעילה יותר מאשר כלים המבוססים על פותרנים מסורתיים בלבד.

ההשפעה של בינה מלאכותית על סימולציה ניכרת בבירור גם בהנדסת חומרים, שם ניבוי תכונות והתנהגויות חומרים תחת עומסים ותנאי סביבה שונים הוא יקר מבחינה חישובית. בינה מלאכותית משמשת כיום לסימולציה של התנהגויות מכניות, תרמיות וכימיות של חומרים חדשים על סמך מאפיינים אטומיים או מיקרו-מבניים. מודלים של למידה עמוקה שאומנו על מערכי נתונים גדולים של חומרים יכולים לחזות תגובות חומרים למאמצים ועומסים שונים, ובכך להפחית את הצורך בבדיקות פיזיקליות מקיפות [62]. יוזמות כמו Materials Genome Initiative (MGI) בארה"ב מדגימות כיצד סימולציה מונעת בינה מלאכותית מאיצה את הגילוי והפריסה של חומרים מתקדמים.

יתר על כן, בינה מלאכותית משנה את שיתוף הפעולה בין אדם למכונה בסימולציה באמצעות תכן גנרטיבי ובינה מלאכותית מוסברת (XAI)⁸⁶. כלי תכן גנרטיביים משתמשים בבינה מלאכותית כדי לחקור באופן


⁸⁴ Bayesian neural networks

⁸⁵ design of experiments (DOE)

⁸⁶ eXplainable AI (XAI)

אוטומטי מגוון עצום של חלופות, ולייצר פתרונות בעלי ביצועים גבוהים שאולי מהנדסים לא שקלו. לאחר מכן, פתרונות אלה מאומתים באמצעות סימולציה. בינתיים, טכניקות של בינה מלאכותית מוסברת עוזרות למהנדסים להבין את תהליך קבלת ההחלטות העומד מאחורי פלטי סימולציה שנוצרו על ידי בינה מלאכותית, להגביר את האמון בתוצאות ולהקל על שיקול דעת הנדסי. (Ribeiro et al., 2016) זה חשוב עבור תחומים קריטיים לבטיחות כמו תעופה וחלל וביטחון, שבהם החלטות חייבות להיות ניתנות למעקב ולאימות.

למרות התקדמות זו, נותרו אתגרים במימוש מלא של הפוטנציאל של בינה מלאכותית בסימולציה. סוגיות מרכזיות כוללות את הצורך בנתוני אימון באיכות גבוהה, הסיכון להתאמת יתר או הכללה לקויה, והקושי בשילוב מודלים של בינה מלאכותית עם תוכנות סימולציה מדור קודם. ביישומים קריטיים לבטיחות, חוסר נאמנות ופרשנות מובטחת בחלק ממודלי הבינה המלאכותית מגביל את השימוש בהם ככלים עצמאיים, ומחייב גישות היברידיות המשלבות מודלים מסורתיים מבוססי פיזיקה עם שיפורים בבינה מלאכותית. בנוסף, מסגרות רגולטוריות והסמכה עדיין מתפתחות כדי להתאים לסימולציות המונעות על ידי בינה מלאכותית, במיוחד בתעשיות כמו תעופה ובריאות⁸⁷. תת-תחומים של שילוב למידת מכונה וסימולציה מתוארים באיור 11-1.



איור 11-1 - שילוב דו כיווני של למידת מכונה וסימולציה (Source: ChatGPT)

⁸⁷ Combining Machine Learning and Simulation to a Hybrid Modelling Approach: Current and Future Directions
https://link.springer.com/chapter/10.1007/978-3-030-44584-3_43

תחומי משנה בשילוב למידת מכונה וסימולציה

לתחומי למידת המכונה (**Machine Learning**) והסימולציה (**Simulation**) קיים אזור חפיפה, אותו אנו מסווגים לשלושה תחומי משנה:

1. למידת מכונה בסיוע סימולציה: (Simulation-assisted machine learning) מתארת שילוב של סימולציות בתוך תהליכי למידת מכונה.
2. סימולציה בסיוע למידת מכונה: (Machine-learning assisted simulation) מתארת שילוב של מודלי למידת מכונה בתוך סימולציות.
3. **שילוב היברידי: (Hybrid combination)** מתאר שילוב בין למידת מכונה לסימולציה המאופיין ביחסי גומלין הדוקים (**Mutual interplay**) בין שני התחומים.

המחקר מתמודד עם האתגרים המוזכרים לעיל. רשתות נוירונים מבוססות פיזיקה (PINN)⁸⁸, למשל, מגשרות על הפער בין למידה מונעת נתונים לבין מידול מבוסס פיזיקה על ידי הטמעת חוקים פיזיקליים בתהליך הלמידה (Raissi et al., 2019) [157]. מודלים אלה מציעים הבטחה לאמינות והכללה גבוהה יותר, במיוחד כאשר נתוני סימולציה דלילים או יקרים לייצור. בינתיים, טכניקות למידה באמצעות העברה ומטה-למידה⁸⁹ מאפשרות שימוש חוזר במודלים של בינה מלאכותית במשימות סימולציה שונות, מגדילות את המעשיות שלהם ומפחיתות את זמן הפיתוח.

לסיכום, בינה מלאכותית מעצבת מחדש באופן דרמטי את נוף הסימולציה ההנדסית על ידי הצגת בינה מונעת נתונים, מהירות, אוטומציה ויכולת הסתגלות. החל מהפעלת תאומים דיגיטליים בזמן אמת ואופטימיזציה של מרחבי עיצוב מורכבים ועד לטיפול בחוסר ודאות ושיפור מידול רב-פיזיקלי, בינה מלאכותית מגבירה את יכולות הסימולציה כמעט בכל תחום הנדסה. בעוד שהאתגרים נמשכים, המסלול ברור: סימולציה מוגברת על ידי בינה מלאכותית תהפוך למרכיב חיוני בפרקטיקה ההנדסית המודרנית, ותאפשר מחזורי חדשנות מהירים יותר, עיצובים בטוחים יותר ומוצרים חכמים יותר. ככל שהכלים והמתודולוגיות ממשיכים להתפתח, שילוב הבינה המלאכותית עם סימולציה טומן בחובו את ההבטחה לפתיחת רמות חסרות תקדים של יעילות ויצירתיות בהנדסה.

במאמר שכותרתו היא - תאומים דיגיטליים: היבטים אסטרטגיים ומתודולוגיים [159] - דנים הכותבים רון קנת, גבריאל דוידאן ויעקב בורטמן בנושא תאומים דיגיטליים המייצגים מעבר מהנדסה נומינלית להנדסת ביצועים. אמולטורים הם מרכיב מפתח בטרנספורמציה זו. אמולטורים, המכונים גם מודלים חלופיים או מטא-מודלים, מספקים יכולות ניטור ואבחון. בפרט הכותבים מתמקדים במטרה המשלבת ביצועים אופטימליים וחזקים הנגזרים מאמולטורים סטוכסטיים. הם מדגימים את המתודולוגיה באמצעות שתי דוגמאות בקוד פתוח ומראים כיצד ניתן להשתמש באמולטורים כדי להשלים מודלים חישוביים של אלמנטים סופיים ודינמיקת נוזלים חישובית במסגרות תאומים דיגיטליים. מקרי המבחן כוללים מערכת מכנית ותהליך ייצור ביולוגי.

⁸⁸ Physics-informed neural networks (PINNs)

⁸⁹ Meta-learning, also known as "learning to learn," is a machine learning approach where algorithms are trained to learn how to learn more efficiently on new, related tasks.

11.2. השפעת בינה מלאכותית על הנדסת גורמי אנוש

שילוב הבינה המלאכותית (AI) בהנדסת גורמי אנוש (HFE) שינה באופן משמעותי את התכן, ההערכה והאופטימיזציה של אינטראקציות בין אדם למערכת. הנדסת גורמי אנוש מתמקדת באופן מסורתי בשיפור ביצועי המערכת, הבטיחות ושביעות רצון המשתמשים על ידי התחשבות ביכולות ובמגבלות האנושיות. בינה מלאכותית משפרת תהליך זה על ידי מתן אפשרות למערכות אדפטיביות, מונחות נתונים וחיזוי, המתאימות טוב יותר להתנהגות אנושית, לקוגניציה ולארגונומיה. הקשר הסימביוטי בין בינה מלאכותית ל HFE-מטפח מערכות חכמות ואינטואיטיביות יותר בתעשיות כמו שירותי בריאות, תעופה, ייצור וטכנולוגיית צריכה.

אחת ההשפעות העמוקות ביותר של בינה מלאכותית בהנדסת גורמי אנוש היא פיתוח מערכות אדפטיביות - טכנולוגיות המתאימות באופן דינמי את התנהגותן על סמך קלט אנושי בזמן אמת או נתונים הקשריים. אלגוריתמים של בינה מלאכותית יכולים לנטר אותות פיזיולוגיים (למשל, תנועות עיניים, שונות קצב לב, פעילות מוחית) כדי להעריך עייפות, לחץ או עומס עבודה קוגניטיבי של המשתמש, מה שמאפשר למערכות להגיב בהתאם, כגון התאמת רמות אוטומציה בכלי רכב או התאמת ממשקי משתמש בסביבות בסיכון גבוה כמו בקרת תנועה אווירית [160].

בינה מלאכותית גם מקדמת עיצוב ממוקד אדם על ידי תמיכה במידול ניבוי של התנהגות משתמש. טכניקות למידת מכונה מנתחות מערכי נתונים גדולים על אינטראקציה אנושית כדי לחשוף דפוסי שימוש, לצפות שגיאות ולמטב ממשקים לפני יישום בקנה מידה מלא. יכולת זו מסייעת להפחית את ההסתמכות על שלבי בדיקת משתמשים יקרים וגוזלי זמן. לדוגמה, מודלים ניבויים שימשו בתכן תא טייס כדי לצפות שגיאות טייס ולעצב מחדש תצוגות כדי למזער סיכונים [161].

יתר על כן, בינה מלאכותית מאפשרת מערכות תמיכה חכמות בהחלטות (IDSS)⁹⁰ המשפרות את שיקול הדעת האנושי במשימות מורכבות. בתחום הבריאות, מערכות IDSS המונעות על ידי בינה מלאכותית מסייעות לרופאים על ידי פירוש תמונות רפואיות או ניבוי אבחנות, ובכך מפחיתות את העומס הקוגניטיבי ומאפשרות קבלת החלטות מהירות ומדויקות יותר [162]. עם זאת, מערכות כאלה חייבות להיות מתוכננות תוך שימת לב לאמון אנושי ולשקיפות כדי להבטיח שימוש מתאים ולהימנע מהסתמכות יתר. תחום מחקר זה הולך וגדל בתוך מערכות HFE.

יישום בולט נוסף הוא בארגונומיה ובעיצוב מקום עבודה [163]. מערכות לכידת תנועה וראייה ממוחשבת המונעות על ידי בינה מלאכותית מעריכות את היציבה והתנועה האנושית בזמן אמת, ומסייעות בזיהוי סיכונים להפרעות שלד-שרירים ומספקות מידע על תכן תחנות עבודה בטוחות ויעילות יותר [164]. רובוטיקה ובינה מלאכותית הן גם מרכזיות בסביבות עבודה שיתופיות, כגון קובוטים (רובוטים שיתופיים), המקיימים אינטראקציה עם עובדים אנושיים. הבטחת בטיחות, אינטראקציה אינטואיטיבית וחלוקת עומס עבודה נכונה דורשת יישור הדוק עם עקרונות HFE.

למרות התקדמות זו, האתגרים עדיין קיימים. יש לטפל בשיקולים אתיים, כולל פרטיות נתונים, הטיה אלגוריתמית ויכולת הסבר, כדי לשמור על אמון המשתמשים. בנוסף, מערכות בינה מלאכותית עלולות לעיתים ליצור שאננות באוטומציה או להפחית את המודעות למצב אם הן משולבות בצורה גרועה, דבר

⁹⁰ intelligent decision support systems (IDSS)

המדגיש את הצורך בשיתוף פעולה מתמשך בין מפתחי בינה מלאכותית לאנשי מקצוע בתחום הנדסת גורמי אנוש (HFE).

לסיכום, בינה מלאכותית היא גורם רב עוצמה המאפשר התקדמות בהנדסת גורמי אנוש. היא מביאה יכולות חסרות תקדים להבנה, חיזוי ותמיכה בהתנהגות אנושית במערכות מורכבות. ככל שטכנולוגיות בינה מלאכותית מתפתחות, שילובן המוצלח במערכות ממוקדות אדם יהיה תלוי ביישום קפדני של עקרונות HFE כדי להבטיח בטיחות, יעילות וקבלת משתמשים.

11.3. השפעת בינה מלאכותית על הנדסת איכות

בשנת 2024, אין תחום שבו בינה מלאכותית (AI) לא השאירה את חותמה, ומערכות אבטחת איכות וניהול איכות אינן יוצאות דופן [16,17]. עם הטכנולוגיה שמשנה את האופן שבו עסקים מנהלים את תקני האיכות ופרוטוקולי התאימות שלהם, בינה מלאכותית תעלה את היעילות והאפקטיביות של מערכות אלו.

תוכנת ניהול איכות המשלבת טכנולוגיית בינה מלאכותית היא הדבר הגדול הבא בתחום אבטחת האיכות. בינה מלאכותית וטכנולוגיות נלוות אליה, כגון למידת מכונה ועיבוד שפה טבעית, מגדירות מחדש את את ניהול התאימות ובדיקות האיכות על ידי הפיכתן לאמינות ומדויקות יותר. איור 2-8.3 מתאר את ההתפתחות של מערכת אבטחת איכות ושילוב בינה מלאכותית.

השימוש בבינה מלאכותית במערכות ניהול איכות

בינה מלאכותית (AI) משנה את הנוף של מערכות ניהול איכות (QMS) על ידי שיפור הדיוק, היעילות ויכולות קבלת ההחלטות בתעשיות השונות. באופן מסורתי, מסגרות QMS הסתמכו במידה רבה על תהליכים ידניים וגישות מגיבות כדי להבטיח תאימות, להפחית פגמים ולשמור על איכות המוצר או השירות. עם זאת, עם שילוב טכנולוגיות בינה מלאכותית - כגון למידת מכונה, עיבוד שפה טבעית ואנליטיקה ניבויית (predictive analytics) - ניהול האיכות הופך להיות פרואקטיבי, מונחה נתונים ואדפטיבי יותר ויותר.

אחד ההיתרונות העיקריים של בינה מלאכותית ב-QMS הוא יכולתה לנתח כמויות עצומות של נתונים מובנים ולא מובנים כדי לזהות דפוסים, אנומליות ומגמות שעלולות לחמוק מעיניהם של פקחים אנושיים. זה מאפשר זיהוי מוקדם של בעיות איכות, ניתוח גורמי שורש וניטור בזמן אמת, מה שמפחית משמעותית את הסיכון לאי-התאמה וקריאות החזר (Recalls) יקרים של מוצרים תקולים. כלים המופעלים על ידי בינה מלאכותית יכולים גם להפוך תיעוד, ביקורות ובדיקות תאימות לאוטומטיות, למזער טעויות אנוש ולשחרר משאבים למשימות בעלות ערך גבוה יותר.



איור 1-11 השפעות בינה מלאכותית בניהול איכות (Source: ChatGPT)

בתעשיות ייצור, בריאות, תרופות ותעשיות מפוקחות אחרות, בינה מלאכותית משפרת את העמידה בתקני איכות בינלאומיים כגון ISO 9001, ICH Q10 או תקנות ה-FDA על ידי תמיכה בשיפור מתמיד וקידום חשיבה מבוססת סיכונים. תחזוקה חזויה, אופטימיזציה של תהליכים ותמיכה חכמה בקבלת החלטות הופכות לחלקים בלתי נפרדים ממסגרות ניהול איכות מודרניות.

יתר על כן, בינה מלאכותית יכולה להתאים אישית את אבטחת האיכות על ידי למידה מניסיון העבר והסתגלות לשינויים בשרשראות אספקה, בסביבות ייצור או בציפיות הלקוחות. יכולת דינמית זו תומכת בחדשנות תוך שמירה על סטנדרטים מחמירים של איכות.

ככל שבינה מלאכותית ממשיכה להתבגר, תפקידה במערכת ניהול האיכות צפוי להתרחב, ויציע הזדמנויות חדשות לשיפור השקיפות, המעקב והיעילות לאורך מחזור חיי האיכות. עם זאת, יישום מוצלח דורש שילוב

מדוקדק עם מערכות קיימות, שיקולים אתיים ופיקוח מתמשך כדי להבטיח שכלי בינה מלאכותית משלימים - ולא מחליפים - שיקול דעת אנושי בהחלטות איכות קריטיות.

השימוש בבינה מלאכותית במערכות ניהול איכות בתכן הנדסי

בינה מלאכותית (AI) מחוללת מהפכה במערכות ניהול איכות (QMS) בתכן הנדסי על ידי הצגת כלים חכמים המשפרים דיוק, יעילות וחדשנות [17]. תכן הנדסי, המאופיין במורכבות, איטרציות ושיתוף פעולה רב-תחומי, דורש סטנדרטים גבוהים של איכות כדי להבטיח פונקציונליות מוצר, בטיחות ועמידה בתקנות. טכנולוגיות בינה מלאכותית - כגון למידת מכונה, אלגוריתמי אופטימיזציה וניתוח נתונים - משולבות יותר ויותר במערכות ניהול איכות כדי לתמוך ביעדים אלה משלבי התכן המוקדמים ביותר.

יתרון מרכזי אחד של בינה מלאכותית בניהול איכות תכן הנדסי הוא יכולתה לנתח מערכי נתונים גדולים מפרויקטים קודמים, סימולציות וביצועים בעולם האמיתי כדי לחזות פגמים או כשלים פוטנציאליים בתכן לפני בניית אבות טיפוס פיזיים. יכולת חיזוי זו מסייעת בהפחתת איטרציות תכן יקרות, מאיצה את זמן היציאה לשוק ומשפרת את האמינות. כלים מונעי בינה מלאכותית יכולים גם לתמוך בתהליכי אימות ותיקוף תכן על ידי אוטומציה של בדיקות תאימות מול סטנדרטים ומפרטים, זיהוי סטיות בזמן אמת והצעת פעולות מתקנות.

יתר על כן, בינה מלאכותית מאפשרת שיפור מתמיד בתהליכים הנדסיים על ידי למידה מהחלטות תכן היסטוריות ותוצאות. לדוגמה, תכן גנרטיבי - המופעל על ידי בינה מלאכותית - יכול ליצור ולהעריך אלפי חלופות תכן במסגרת אילוצים מוגדרים, ובכך להבטיח שהבחירה הסופית מיטבית את הביצועים, העלות ויכולת הייצור. זה תורם למערכת ניהול איכות חזקה וגמישה יותר, המגיבה באופן דינמי למידע חדש ולדרישות פרויקט מתפתחות.

בינה מלאכותית גם משפרת את שיתוף הפעולה בין צוותי הנדסה על ידי שילוב נתוני תכן עם מדדי איכות, עידוד קבלת החלטות מושכלות וצמצום פערים בתקשורת. יכולות אלו הופכות את מערכת ניהול האיכות לא רק למנגנון בקרה אלא גם לכלי אסטרטגי המאפשר חדשנות ומצוינות בתכן.

ככל שבינה מלאכותית תשתלב יותר בתהליכי עבודה הנדסיות, תפקידה באבטחת איכות יתרחב, וידרוש מארגונים לאזן בין אוטומציה לפיקוח אנושי, להבטיח שקיפות בהחלטות המונעות על ידי בינה מלאכותית, וליישר כלים עם תקנות וסטנדרטים אתיים ספציפיים לתעשייה.

11.4. מחזור החיים של מוצר חדש כולל הנדסת ייצור, תכן להרכבה, הנדסת תחזוקתיות, עיצוב/תכן לעלות, שיווק ומכירה

תכן לייצור (DFM)⁹¹ באמצעות בינה מלאכותית


תכן לייצור (DFM) הוא מתודולוגיה שמטרתה לפשט את תכן המוצר כדי להפחית את עלויות הייצור, לשפר את האיכות ולקצר את זמן היציאה לשוק. שילוב בינה מלאכותית (AI) ב-DFM משפר משמעותית תהליך זה על ידי מתן אפשרות לאופטימיזציה של תכן מבוסס נתונים, קבלת החלטות אוטומטית וזיהוי מוקדם של בעיות ייצור. כלים המופעלים על ידי בינה מלאכותית, כגון אלגוריתמי תכן גנרטיבי ומודלים של למידת מכונה (ML), מנתחים מערכי נתונים עצומים מקבצי CAD, יומני ייצור ומסדי נתונים של חומרים כדי להמליץ על שינויי תכן התואמים ליכולות ייצור ספציפיות. לדוגמה, בינה מלאכותית יכולה להציע שינויים בגיאומטריה כדי למזער בזבז בייצור תוסף או לייעל את כיוון החלקים בעיבוד שבבי CNC. מודלים של עיבוד שפה טבעית (NLP) מיושמים גם כדי לפרש דרישות תכן ולהצליב אותן עם אילוצי ייצור היסטוריים. יתר על כן, בינה מלאכותית משפרת את שיתוף הפעולה בין צוותי הנדסה וייצור על ידי מתן משוב בזמן אמת על היתכנות התכן, ובכך מפחיתה את מספר האיטרציות. ניתוח ניבוי יכול להעריך סיכוני כשל, להעריך עלויות ולזהות סבילות המובילות לפגמים, והכל לפני בניית אב טיפוס. גישה זו מאיצה מחזורי תכן תוך שיפור יכולת הייצור, יעילות העלות והקיימות. מחקרים שונים בנושא מדגישים את ההשפעה הגוברת של בינה מלאכותית על ניהול תהליכים (DFM), והם מציינים כי מערכות DFM מבוססות בינה מלאכותית הופכות חיוניות לגישור בין כוונת תכן ויכולת ייצור, במיוחד בסביבות ייצור מורכבות ומותאמות אישית. ככל שתהליכי ייצור הופכים לדיגיטליים ואוטונומיים יותר, DFM משולב בבינה מלאכותית יהיה קריטי בשמירה על יתרון תחרותי ובעמידה בדרישות הלקוחות המתפתחות בזמן אמת [99,98,100].

להלן פירוט מפורט של המרכיבים השונים בייצור:

1. תכן גנרטיבי: בינה מלאכותית יכולה לייצר אפשרויות תכן מרובות המבוססות על פרמטרים מוגדרים מראש, אילוצי חומרים ודרישות ביצועים. זה מאפשר למעצבים לחקור מגוון רחב יותר של אפשרויות ולזהות תכנים אופטימליים שאולי לא יתגלו בשיטות מסורתיות.
2. סימולציה וניתוח: כלים המופעלים על ידי בינה מלאכותית יכולים לדמות ביצועי מוצר בתנאים שונים, כגון מאמץ, התנהגות תרמית ודינמיקת נוזלים. זה עוזר לזהות פגמי תכן פוטנציאליים בשלב מוקדם של התהליך, להפחית את הצורך באבות טיפוס פיזיים ולהאיץ את הפיתוח.
3. אופטימיזציה אוטומטית של תכן: אלגוריתמים של בינה מלאכותית יכולים לייעל אוטומטית תכנים המבוססים על קריטריונים של ביצועים, בחירת חומרים ואילוצי ייצור. זה יכול להוביל למוצרים קלים, חזקים וחסכוניים יותר.
4. תהליכי ייצור משופרים: בינה מלאכותית יכולה לייעל תהליכי ייצור, כגון עיבוד שבבי CNC והדפסה תלת-ממדית, על ידי התאמת פרמטרים, ניבוי צרכי תחזוקה ושיפור היעילות הכוללת.

⁹¹ Design for Manufacturing (DFM) Using AI

5. תחזוקה חזויה: בינה מלאכותית יכולה לנתח נתוני חיישנים מצויד ייצור כדי לחזות כשלים פוטנציאליים ולתזמן תחזוקה באופן יזום, למזער זמן השבתה ולהפחית עלויות.
6. אופטימיזציה של שרשרת האספקה: בינה מלאכותית יכולה לסייע בייעול פעולות שרשרת האספקה על ידי חיזוי ביקוש, ניהול מלאי וזיהוי שיבושים פוטנציאליים.
7. יעילות מוגברת והפחתת עלויות: על ידי אוטומציה של משימות, אופטימיזציה של תכנים ושיפור תהליכי ייצור, בינה מלאכותית יכולה להגביר משמעותית את היעילות ולהפחית עלויות לאורך מחזור חיי המוצר.
8. איכות מוצר משופרת: מערכות בקרת איכות המופעלות על ידי בינה מלאכותית יכולות לזהות פגמים בדיוק ובמהירות גדולים יותר מאשר פקחים אנושיים, מה שמוביל לאיכות מוצר גבוהה יותר ולהפחתת בזבז.
9. שיתוף פעולה וחדשנות משופרים: בינה מלאכותית יכולה להקל על שיתוף פעולה בין מעצבים, מהנדסים ויצרנים על ידי מתן פלטפורמה משותפת לשיתוף נתונים ותובנות. היא יכולה גם לעזור רעיונות תכן חדשים ולהאיץ את פיתוחם של מוצרים חדשניים.



איור 3-11 - תיאור העקרונות של תכן או עיצוב מוצר לייצור (Source: ChatGPT)

11.5. כיצד בינה מלאכותית משנה את עולם הייצור בתחום של Additive Mfg.

מבוא

ייצור תוספתי (AM)⁹², המכונה לרוב הדפסה תלת-ממדית, היא טכנולוגיית ייצור פורצת דרך היוצרת אובייקטים תלת-ממדיים ישירות מעיצובים דיגיטליים על ידי הוספת חומר שכבה על גבי שכבה. תהליך זה שונה באופן מהותי משיטות ייצור מסורתיות, כגון עיבוד שבבי, כרסום או קידוח, אשר מעצבות מוצרים על ידי הסרת חומר מגוש גדול יותר. על ידי הפקדת חומר רק במידת הצורך, ייצור תוסף מאפשר גמישות עיצובית חסרת תקדים, שימוש יעיל במשאבים ויכולת לייצר גיאומטריות מורכבות ביותר שאחרת היו בלתי אפשריות או יקרות באופן בלתי אפשרי לייצור.

במקור ייצור תוספתי (Additive Manufacturing) ניתן לייחס לאמצע שנות ה-80, עם המצאת הסטריאוליתוגרפיה, אחת השיטות הראשונות שהשתמשו באור אולטרה סגול כדי למצק שכבות של פולימר נוזלי. מאז, הטכנולוגיה התגוונה והתבגרה במהירות, והולידה מגוון רחב של טכניקות, כולל מודלים של התכה (FDM)⁹³, סינטור לייזר סלקטיבי (SLS)⁹⁴, התכת קרן אלקטרונים (EBM)⁹⁵ וסינטור ישיר של מתכת בעזרת לייזר (DMLS)⁹⁶. כל שיטה מתאימה לחומרים ויישומים שונים, ומאפשרת שימוש בפלסטיק, מתכות, קרמיקה, חומרים מרוכבים ואפילו ביו-חומרים. רבגוניות חומרית זו הרחיבה את הרלוונטיות של ייצור תומך (ייצור תוספי AM – הוא הרבה מעבר לאב טיפוס, לתחומים כמו תעופה וחלל, רכב, שירותי בריאות, ביטחון ומוצרי צריכה. יתרונות הייצור התוספתי רבים. הוא מאפשר יצירת אב טיפוס באופן מהיר, ומאפשר למהנדסים ולמעצבים לבצע איטרציות ולבדוק קונספטים במהירות ובעלות נמוכה יותר. הוא מפחית בזבז חומרים על ידי שימוש רק בכמות הנדרשת של חומר גלם, בהתאם לשיטות ייצור בנות קיימא. אולי הכי חשוב, AM מאפשר התאמה אישית בקנה מידה גדול - ניתן להתאים מוצרים לצרכים אישיים, כגון שתלים רפואיים ספציפיים למטופל או פריטי צריכה מותאמים אישית, מבלי לדרוש שיפוץ יקר של קווי ייצור.

בשנים האחרונות, AM החלה לעבור מכלי יצירת אב טיפוס לטכנולוגיית ייצור בקנה מידה מלא. התקדמות במהירות, בדיוק ובחוזק החומר אפשרה ליצרנים לשלב AM ביישומים קריטיים, כגון רכיבים מבניים קלים למטוסים, חלקי רכב עמידים ביותר וכלים מדויקים לתעשייה. בתחום הבריאות, מנתחים מסתמכים יותר ויותר על מודלים אנטומיים מודפסים בתלת-ממד ושתלים המותאמים לאנטומיה של המטופל, בעוד שבתחום הבנייה, מדפסות בקנה מידה גדול מייצרות רכיבי בניין ואפילו מבנים שלמים.

⁹² Additive manufacturing (AM)

⁹³ fused deposition modeling (FDM)

⁹⁴ selective laser sintering (SLS)

⁹⁵ electron beam melting (EBM)

⁹⁶ direct metal laser sintering (DMLS)

כחלק מהטרנספורמציה הרחבה יותר של Industry 4.0, ייצור תוספי צפוי להגדיר מחדש את שרשראות האספקה ואסטרטגיות הייצור. על ידי מתן אפשרות לייצור מקומי לפי דרישה והפחתת התלות בייצור המוני מרכזי, ייצור תוספי מציע פוטנציאל לקצר את זמני ההובלה, להפחית עלויות ולקדם חוסן בתעשיות גלובליות. עם חדשנות מתמשכת, הדפסה תלת-ממדית צפויה להפוך לאבן יסוד בנוף הייצור העתידי.

אתגר עיצוב תלת-ממדי

טכנולוגיית הייצור התוספי השתפרה בצעדי ענק מבחינת איכות ועלות בעשור האחרון. אך תכן עבור ייצור תוספי הוא עדיין דורש מערך מיומנויות חדש עבור מהנדסים רבים. גם ספקי תוכנה מסורתיים לתכן וגם חברות חדשות יצרו כלים שיעזרו להפוך את התכן עבור ייצור תוספי לקל ומהיר יותר. בגיליון מיוחד שכותרתו היא: Design for Additive [165] שיצא לאור בחודש ינואר 2026, עורכי Digital Engineering ריכזו את הסיקור האחרון שלהם על כלי DfAM, פיתוחי תוכנה לייצור תוספי וסיקור מתערוכות סחר תוספי אחרונות.

בינה מלאכותית משנה באופן משמעותי את תהליך Additive Manufacturing (AM)

בינה מלאכותית משנה באופן משמעותי את התהליך של ייצור תוספי (AM), המכונה גם הדפסה תלת-ממדית, על ידי שיפור העיצוב, אופטימיזציה של תהליכים ושיפור בקרת האיכות. אלגוריתמי בינה מלאכותית יכולים לנתח ולמטב עיצובים להדפסה תלת-ממדית, להפוך בקרת איכות לאוטומטית ואף לחזות התנהגות חומרים במהלך ההדפסה. זה מוביל לייצור יעיל יותר, הפחתת בזבז ומחזורי פיתוח מוצרים מהירים יותר.

להלן מבט מפורט יותר על אופן יישום הבינה המלאכותית [111,110,109,108]:

1. אופטימיזציה של עיצוב:

- בינה מלאכותית יכולה לנתח עיצובים ותכנונים ולמטב אותם לייצור תוספי, תוך התחשבות בגורמים כמו תכונות חומר ואילוסי הדפסה.
- כלי עיצוב גנרטיביים, המופעלים על ידי בינה מלאכותית, יכולים ליצור באופן אוטומטי אפשרויות עיצוב מרובות המבוססות על פרמטרים מוגדרים, מה שמוביל לעתים קרובות למבנים חדשניים ויעילים.
- כלי עיצוב מונעי בינה מלאכותית יכולים גם לחזות ביצועי חלקים (מאמץ, זרימה, חום) לפני ההדפסה, ובכך להפחית את הצורך באב טיפוס פיזי נרחב.

2. אופטימיזציה של תהליכים:

- אלגוריתמי בינה מלאכותית יכולים למטב פרמטרים של תהליך ייצור תוספי כמו טמפרטורה, מהירות וזרימת חומרים, לשפר את איכות המוצר ולהפחית פגמים.
- ניתן לשלב בינה מלאכותית במערכות למידת מכונה כדי לנטר ולשלוט בתהליך ההדפסה בזמן אמת, ולבצע התאמות כדי להבטיח איכות עקבית.
- מערכות המופעלות על ידי בינה מלאכותית יכולות לחזות בעיות פוטנציאליות לפני שהן מתרחשות, ולמזער את זמן ההשבתה והבזבז.

3. בקרת איכות:

- ניתן להשתמש בבינה מלאכותית כדי לנטר את תהליך ההדפסה בזמן אמת, ולזהות פגמים שעשויים שלא להיות גלויים לעין בלתי מזוינת.
- ניתן לאמן אלגוריתמים של למידת מכונה לזהות סוגים שונים של פגמים, ולהבטיח פלט באיכות גבוהה.
- ניתן להשתמש בבינה מלאכותית גם לאבטחת איכות לאחר עיבוד, ולזהות בעיות פוטנציאליות כאשר המוצרים יוצאים מהקו.

4. פיתוח חומרים:

- בינה מלאכותית יכולה לנתח מערכי נתונים עצומים של תכונות חומרים ולחזות את התנהגותם של חומרים חדשים לייצור תוספי.
- זה יכול להאיץ את פיתוח חומרים חדשים עם תכונות מותאמות אישית ליישומים ספציפיים.

5. תחזוקה חזויה:

- בינה מלאכותית יכולה לנתח נתונים ממכונות ייצור תוספי כדי לחזות צורכי תחזוקה פוטנציאליים, ולמנוע השבתה בלתי צפויה.
 - זה יכול לסייע ביעול ניצול המכונות ולמזער שיבושים בייצור.
- במהותה, בינה מלאכותית משנה את הייצור התוספי על ידי הפיכתו ליעיל, אמין וגמיש יותר, וסוללת את הדרך לאפשרויות חדשות בתכן, ייצור ופיתוח חומרים.

סיכום ועתיד הבינה המלאכותית בייצור תוספתי (הדפסה תלת-ממדית)

עתיד הבינה המלאכותית בייצור תוספי טומן בחובו אפשרויות מבטיחות. התקדמות באלגוריתמים של בינה מלאכותית ופיתוח חומרים וטכנולוגיות חדשים ישפרו גם את יכולות הייצור התוספי. זה ייצור הזדמנויות חדשות לחדשנות ויאפשר ייצור של רכיבים מורכבים ומותאמים אישית אף יותר.

שיפור ושיתוף פעולה בין בעלי עניין בתעשייה, חוקרים וקובעי מדיניות חיוניים למימוש מלוא הפוטנציאל של בינה מלאכותית בייצור תוספי. על ידי עבודה משותפת, נוכל להתמודד עם אתגרים ולפתוח את ההזדמנויות שמציעות טכנולוגיות בינה מלאכותית.

בינה מלאכותית בייצור תוספי משפיעה באופן משמעותי על תעשיות הרכב, התעופה והחלל והביו-רפואה. בינה מלאכותית מאפשרת רמות חדשות של חדשנות ופריון על ידי שיפור יעילות קו הייצור, אופטימיזציה של התכן והבטחת איכות. בעוד שספקנות מסוימת נותרה, התייחסות לחששות הקשורים לאמינות, אתיקה ורגולציה תהיה קריטית להשגת אמון ולמימוש מלוא הפוטנציאל של בינה מלאכותית בהדפסה תלת-ממדית. ככל שאנו ממשיכים לחקור ולפתח טכנולוגיות אלו, עתיד הייצור נראה מבטיח. בינה מלאכותית בחינוך הנדסי ופיתוח מיומנויות.

11.6. שילוב בתוכניות לימודים ותפקיד הבינה המלאכותית

שילוב הבינה המלאכותית בתוכניות לימודים הנדסיות משנה את הנוף החינוכי. מחנכים ממנפים כיום את הבינה המלאכותית כדי ליצור סביבות למידה דינמיות המתאימות לצרכים האישיים של התלמידים. גישה מותאמת אישית זו מבטיחה שהלומדים לא רק בקיאים בהיבטים התיאורטיים של הבינה המלאכותית, אלא גם צוברים ניסיון מעשי ביישום בינה מלאכותית לבעיות מהעולם האמיתי [7178].

קורסים בין-תחומיים המשלבים בינה מלאכותית עם דיסציפלינות הנדסיות מסורתיות הופכים נפוצים יותר ויותר. תוכניות אלו שואפות לצייד את התלמידים במערך מיומנויות הוליסטי המבוקש מאוד בשוק העבודה המודרני. להלן רשימה של יתרונות מרכזיים ששילוב בינה מלאכותית מביא לחינוך הנדסי:

- חוויות למידה משופרות באמצעות אספקת תוכן מותאם אישית
- משוב והערכה בזמן אמת לשיפור שימור הידע
- הזדמנויות לפרויקטים מעשיים הכוללים יישומי בינה מלאכותית
- נדגיש כאן כי נושא זה, בדגש על הכשרת מהנדסי מערכת, יזכה לסקירה נפרדת ומקיפה בהמשך.

גישה על פער המיומנויות באמצעות מערכות הדרכה חכמות

הופעתן של מערכות חכמות (ITS)⁹⁷ מסמנת אבן דרך משמעותית בחינוך ההנדסי. מערכות אלו נועדו לספק חוויות למידה מותאמות אישית, המותאמות לצרכים האישיים של כל תלמיד. ל-ITS יש פוטנציאל לחולל מהפכה באופן שבו מהנדסים מוכשרים, על ידי הצעת הדרכה ומשוב מותאמים אישית שיכולים להאיץ את תהליך הלמידה.

- ITS יכול לזהות תחומים ספציפיים שבהם תלמיד עשוי להתקשות ולספק תרגילים מותאמים אישית לשיפור היכולת של התלמיד.
 - מערכות ITS מאפשרות הערכה מתמשכת, ומאפשרות התאמות בזמן אמת למסלול הלמידה.
 - ITS תומך במגוון רחב של סגנונות למידה, מה שהופך את החינוך למכיל יותר.
- השימוש ב-ITS תואם גם את הביקוש של התעשייה למהנדסים רב-תכליתיים ומהירים להסתגל לטכנולוגיות חדשות. ככל שנוף ההנדסי מתפתח, ITS ימלא תפקיד מכריע בהכנת כוח העבודה להתמודדות עם אתגרי המחר.

השפעת הבינה המלאכותית על פיתוח מקצועי מתמשך

שילוב הבינה המלאכותית בפיתוח מקצועי מתמשך (CPD)⁹⁸ משנה את האופן שבו מהנדסים שומרים ומשפרים את כישוריהם לאורך הקריירה שלהם. פלטפורמות המונעות על ידי בינה מלאכותית מתאימות

⁹⁷ Intelligent Tutoring Systems (ITS)

⁹⁸ continuing professional development (CPD)

חוויות למידה לצרכים האישיים, ומאפשרות לאנשי מקצוע להישאר מעודכנים בהתקדמות הטכנולוגית ובסטנדרטים העדכניים ביותר בתעשייה.

התאמה אישית של המשך פיתוח מקצועי באמצעות בינה מלאכותית לא רק הופכת את הלמידה ליעילה יותר, אלא גם מעוררת עניין רב יותר. על ידי ניתוח נתוני ביצועים, בינה מלאכותית יכולה להמליץ על קורסים, לחזות פערים במיומנויות ואף להציע הזדמנויות נטוורקינג התואמות את יעדי הקריירה.

- ניתוח מבוסס בינה מלאכותית לזיהוי מגמות מיומנויות
- מסלולי למידה מותאמים אישית לכל מהנדס
- משוב בזמן אמת וטכניקות למידה אדפטיביות

11.7. יישומי בינה מלאכותית בהנדסת יצור

אופטימיזציה של שרשרת אספקה (144, 145)

על ידי הקדשת זמן ומשאבים לאופטימיזציה, נוכל ליצור שרשראות אספקה חזקות ובנות קיימא יותר, להפחית בזבז ולבנות חוסן בתהליכים. ניתן להשתמש בבינה מלאכותית ולמידת מכונה בשרשראות אספקה במגוון דרכים המובילות לתוצאות וביצועים משופרים.

AI Use Case	Outcome
Predict and forecast future demand	Optimized inventory control
Track and manage inventory in real time	Improved live inventory systems
Analyze datasets to discover potential risks	Fewer chances for defects and better risk management

ייצור חכם – Smart Manufacturing

ייצור חכם משלב מכשירים ותוכנות חכמות בתהליכי ייצור. שילוב חיישני IoT ובינה מלאכותית בייצור יכול להוביל לשיפורים בדיוק, ביעילות ובתחזוקה הכוללת. שילובים חכמים בייצור מאפשרים גם לעובדים להיות פחות מעורבים בתהליך הייצור, משפרים את הבטיחות ומפחיתים את הסיכון לפציעות על הרצפה.

תחזוקה חזויה - Predictive Maintenance

קריטי עבור מהנדסי תעשייה ומהנדסי מערכות הוא השימוש בבינה מלאכותית בתחזוקה חזויה. תחזוקה חזויה מסייעת לארגונים לבצע התאמות ולתחזק מערכות לפני שבעיות הבלאי הופכות לחמורות עד כדי כך שהן מובילות להשבתה. עם זאת, חיזוי מתי מערכות ידרשו תחזוקה מראש יכול להיות משימה קשה.

לבינה מלאכותית ולמידת מכונה יש את היכולת לנתח מערכי נתונים עצומים ולזהות דפוסים שתוכנה מסורתית עשויה לפספס, מה שמוביל לתחזיות מדויקות יותר ובסופו של דבר, פחות זמן השבתה. עבור מערכות מסוימות כמו רשתות אספקת חשמל ותשתיות אינטרנט, זה יכול להיות קריטי.

רובוטיקה ומערכות אוטונומיות

בינה מלאכותית שינתה את האופן שבו אנו ניגשים לרובוטיקה. על ידי תכן מודלים יעילים תוך התחשבות בפיתוח אתי, מהנדסים יכולים ליצור מערכות אוטונומיות ביותר בפחות מאמץ מאשר רובוטיקה מסורתית, הדורשת תכנות מקדים ומדוקדק לכל תרחיש. יכולות הבינה המלאכותית אפשרו לרובוטים "לקבל החלטות" ולפעול באופן אוטונומי בהקשרים מסוימים, תוך ניצול תפיסה מתקדמת המאפשרת להם לתקשר באופן משמעותי עם הסביבה סביבם.

השפעת בינה מלאכותית על ההנדסה ועל תהליכים תעשייתיים

קשה להפריז בהשפעות של בינה מלאכותית על מגוון תעשיות. יישומים אלה הובילו לשיפורים בתחומים הבאים: יעילות, בטיחות, מסגרות חיזוי, תזמון תחזוקה, קבלת החלטות, אוטומציה.

לבינה מלאכותית הייתה השפעה חזקה במיוחד על תהליכים תעשייתיים, מערכות תעשיות, מערכות מכניות ותכן מכני, ותכנונים הנדסיים בנושא תעופה, שמטרתם לייצר בבטחה, ביעילות ובאפקטיביות רכיבים, חלקים ומכונות המניעים את חיי היומיום. שיפור תהליכי הנדסה באמצעות בינה מלאכותית משפיע על כולם, מה שהופך לא רק את הטכנולוגיה ליעילה יותר, אלא גם את חייהם של המהנדסים והציבור.

11.8. הנדסה בת קיימא: בינה מלאכותית לעיצוב ידידותי לסביבה

בינה מלאכותית בהערכת מחזור חיים ובחירת חומרים (147)

שילוב הבינה המלאכותית בהערכת מחזור חיים (LCA)⁹⁹ ובחירת חומרים משנה את האופן שבו מהנדסים ניגשים לעיצוב בר-קיימא. אלגוריתמי בינה מלאכותית יכולים לנתח מערכי נתונים עצומים כדי לזהות חומרים שלא רק עומדים בדרישות הטכניות של הפרויקט אלא גם ממזערים את ההשפעה הסביבתית. תהליך זה, המשופר על ידי למידת מכונה, מוביל להחלטות מושכלות יותר התורמות לקיימות של פרויקטים הנדסיים.

הערכת מחזור חיים היא כלי קריטי להערכת ההיבטים הסביבתיים וההשפעות הפוטנציאליות הקשורות למוצר לאורך מחזור חייו. על ידי שילוב בינה מלאכותית, הדיוק והמהירות של הערכות אלו משתפרים משמעותית.

⁹⁹ lifecycle assessment (LCA)

מהנדסים יכולים כעת לדמות תרחישים שונים ולחזות תוצאות בדיוק רב יותר, תוך הבטחה שנבחרו החומרים והתהליכים הידידותיים ביותר לסביבה כמתואר להלן.

- זיהוי חומרים בני קיימא
- אופטימיזציה של ניצול משאבים
- הפחתת פסולת ופליטות

עם זאת, יישום הבינה המלאכותית בתחום זה אינו חף מאתגרים. הבטחת האימון והלמידה של מערכות הבינה המלאכותית על נתונים איכותיים ומייצגים היא קריטית לאמינות התחזיות שלהן. יתר על כן, יש לנהל בקפידה רבה את המורכבות של שילוב מערכות אלו בזרימות עבודה קיימות כדי להשיג את התוצאות הטובות ביותר.

כמו כן בינה מלאכותית משנה הנדסה בת קיימא על ידי האצת תכנון ידידותי לסביבה באמצעות סימולציות מהירות ב-99% של אנרגיה, תאורה ופחמן, המאפשרות קבלת החלטות מהירות ומונחות נתונים באדריכלות, הנדסה ובנייה¹⁰⁰ (AEC). בינה מלאכותית ממטבת את בחירת החומרים, מפחיתה פסולת באמצעות מידול גנרטיבי ומגבירה את יעילות האנרגיה, ומציעה נתיב בר-קיימא ומהיר יותר לתשתיות ירוקות יותר (146).

אופטימיזציה של יעילות אנרגטית בעזרת למידת מכונה

שילוב אלגוריתמי למידת מכונה (ML) באופטימיזציה של יעילות אנרגטית מייצג קפיצת מדרגה משמעותית בהנדסה בת קיימא. מודלים של למידת מכונה יכולים לחזות ולמטב את צריכת האנרגיה במערכות שונות, החל מתהליכים תעשייתיים בקנה מידה גדול ועד מכשירי חשמל ביתיים, מה שמוביל להפחתה משמעותית בצריכת האנרגיה ובפליטות הפחמן.

על ידי ניתוח נתונים היסטוריים וקליטת נתונים בזמן אמת, אלגוריתמי למידת מכונה יכולים לזהות דפוסים וחוסר יעילות שלא יהיו מורגשים לעין האנושית. זה מאפשר התאמה דינמית של צריכת האנרגיה, תוך הבטחה שהמערכות יפעלו ביעילות שיא בכל עת. לדוגמה, במערכות HVAC¹⁰¹, למידת מכונה יכולה למטב את הגדרות הטמפרטורה ואת זרימת האוויר, וכתוצאה מכך לגרום לחיסכון באנרגיה מבלי לפגוע בנוחות המשתמש.

תפקידה של בינה מלאכותית בתכן מערכות אנרגיה מתחדשת

שילוב הבינה המלאכותית בתכן מערכות אנרגיה מתחדשת משנה את האופן שבו אנו מנצלים משאבים טבעיים. אלגוריתמי ניתוח חיזוי ולמידת מכונה של בינה מלאכותית הם מרכזיים ביצירת מערכות אנרגיה סולארית שלא רק ממקסמות את היעילות אלא גם מסתגלות לתנאי סביבה משתנים.

¹⁰⁰ Architecture, Engineering, and Construction (AEC).

¹⁰¹ HVAC is an acronym that stands for Heating, Ventilation, and Air Conditioning.

לדוגמה, בתכנ מערכות אנרגיה סולארית, בינה מלאכותית יכולה לנתח כמויות עצומות של נתונים מטאורולוגיים כדי לקבוע את המיקום והזווית האופטימליים של פאנלים סולאריים. זה מבטיח שהמערכות ייצרו את כמות האנרגיה המרבית לאורך כל השנה.

- אופטימיזציה של מיקום פאנלים
 - חיזוי תפוקת אנרגיה
 - תזמון תחזוקה
 - התאמות מערכת בזמן אמת
- על ידי מינוף בינה מלאכותית, מהנדסים יכולים ליצור עיצובים מודרניים המנצלים את המרב ממקורות אנרגיה טבעיים, מה שמוביל לפתרונות בני קיימא וחסכוניים יותר.
- יכולת הסתגלות היא תכונה מרכזית עבור מהנדסים בעתיד משולב בינה מלאכותית. עליהם להרגיש בנוח עם שינוי ולהיות להוטים לרכוש מיומנויות חדשות. כדי להקל על מעבר זה, הצעדים הבאים הם קריטיים:
- עידוד תרבות של למידה לכל החיים בקהילת ההנדסה.
 - פיתוח תוכניות הכשרה ייעודיות המתמקדות בבינה מלאכותית ויישומיה בהנדסה.
 - יצירת שותפויות בין התעשייה למוסדות חינוך כדי לספק ניסיון מעשי בטכנולוגיות בינה מלאכותית.

12. סיכום- מהפכת החדשנות הבאה בהנדסה - מונעת על ידי בינה מלאכותית

על פי דו"ח של חברת McKinsey [55], בינה מלאכותית כבר לא נועדה רק ליעילות. היא יכולה להכפיל את קצב המחקר והפיתוח ולשחרר ערך של עד חצי טריליון דולר בשנה.

על פי הדוח אף שהמדע מתקדם, פרודוקטיביות המחקר והפיתוח בירידה על פי מדדים רבים, ובתחומים רבים, כל דולר שהוצא על מחקר ופיתוח קונה פחות חדשנות לאורך זמן. במילים אחרות, פרודוקטיביות המחקר והפיתוח נמצאת בירידה.

קחו לדוגמה את תעשיית המוליכים למחצה. עם מעגלים משולבים המוטמעים במוצרים התומכים כמעט בכל חלק בחיינו, מגזר זה התקדם בהתאם ל"חוק מור" - התצפית המדהימה שהציג מייסד אינטל, גורדון מור, לפיה מספר הטרנזיסטורים במעגל משולב יוכפל בערך כל שנתיים. זה שווה ערך בערך לקצב צמיחה אקספוננציאלי של 35 אחוזים בשנה בטרנזיסטורים לדולר.

אבל רמת שיפור ביצועים זו נקנתה במחיר של עלייה בהוצאות על מחקר ופיתוח. ניקולס בלום, פרופסור לכלכלה באוניברסיטת סטנפורד, ועמיתיו למחקר פרסמו מאמר בשנת 2020 שבחן את הוצאות המו"פ האמיתיות של חברות מוליכים למחצה ויצרני ציוד והעריכו כי מאמץ המחקר השנתי שלהם גדל פי 18 בין 1971 ל-2014. במילים אחרות, שמירה על קצב צמיחת הביצועים בחוק מור דרשה פי 18 יותר הוצאות מו"פ מותאמות לאינפלציה בשנת 2014 מאשר בשנת 1971.

בעשור האחרון ראינו כיצד בינה מלאכותית, בשילוב עם שיטות ניהול משלימות כדי לעצב מחדש את אופן פעולתן של ארגונים, יכולה לייצר ערך עסקי אמיתי. עוד לפני הופעתה של בינה מלאכותית יוצרת, בינה מלאכותית אנליטית הייתה בשימוש על ידי כמחצית מהארגונים המיוצגים בסקר הגלובלי של מקינזי בנושא בינה מלאכותית. ארגונים אלה פרסו את הטכנולוגיה במגוון פונקציות עסקיות - החל מהגדלת הכנסות באמצעות שיווק ממוקד יותר ועד להפחתת עלויות בפעולות שרשרת האספקה. מאז ש-ChatGPT הפך לזמין בסוף 2023, אחוז הארגונים המדווחים שהם משתמשים בבינה מלאכותית זינק כלפי מעלה ב-עשרות אחוזים, כאשר חברות מיישמות בינה מלאכותית בתחומים רבים, החל משירות לקוחות ועד להנדסת תוכנה והנדסה בכלל.

רוב היישומים הללו של בינה מלאכותית נועדו לשפר את היעילות של משימות וזרימות עבודה קיימות. אך הגברת היעילות והפרודוקטיביות היא רק דרך אחת שבה בינה מלאכותית מבטיחה לפתוח עידן חדש של צמיחה והזדמנויות. המחקר מראה שניתן לפרוס בינה מלאכותית גם כדי להאיץ חדשנות וליצור מוצרים ושירותים חדשים לחלוטין. במילים אחרות: ניתן להשתמש בבינה מלאכותית כדי לכופף את עקומות הירידה בפריין המחקר והפיתוח שתיעדנו בסעיף הקודם. זיהינו שלושה ערוצים עיקריים שדרכם טכנולוגיות בינה מלאכותית יכולות להאיץ חדשנות, לכל אחד סוג מודל מתאים: הגדלת המהירות, הנפח והמגוון של יצירת מועמדים לעיצוב; האצת הערכת מועמדים באמצעות מודלים של בינה מלאכותית; והאצת פעולות מחקר.

הנדסה וטכנולוגיה קשורות זו בזו במעגל מתמשך. התקדמות בהנדסה מובילה לטכנולוגיות חדשות, אשר בתורן מניעות חידושים הנדסיים נוספים. התפתחויות טכנולוגיות חדשות מתרחשות מדי יום, אך חלק מההתפתחויות הופכות כה משמעותיות עד שהשפעתן ניכרת הן על מהנדסים והן על הציבור הרחב.

References and Sources

1. AI4SE & SE4AI Workshop 2023. Sep 27-28, 2023 - Washington, DC
SYSTEMS Engineering Research Center
2. 9 benefits of artificial intelligence (AI) in 2026, University of Cincinnati ,
<https://www.online.uc.edu/blog/artificial-intelligence-ai-benefits.html>
3. A comprehensive literature review of the applications of AI techniques through the lifecycle of industrial equipment. <https://link.springer.com/article/10.1007/s44163-023-00089-x>
4. Applications of artificial intelligence in engineering and manufacturing: a systematic review. Published: 15 April 2021. Volume 33, pages 1581–1601, (2022). <https://link.springer.com/article/10.1007/s10845-021-01771-6?fromPaywallRec=false>
5. Review of artificial intelligence applications in engineering design perspective.
<https://doi.org/10.1016/j.engappai.2022.105697>
6. Mapping artificial intelligence-based methods to engineering design stages: a focused literature review. Published online by Cambridge University Press: 12 December 2023.
<https://www.cambridge.org/core/journals/ai-edam/article/mapping-artificial-intelligencebased-methods-to-engineering-design-stages-a-focused-literature-review/706442DFC0F1213F01997072DFD71A3C>
7. The new V-Model of VDI 2206 and its validation. Iris Graessler and Julian Hentze. Published/Copyright: April 30, 2020. <https://www.degruyterbrill.com/document/doi/10.1515/auto-2020-0015/html>
8. The impact of AI on engineering design procedures for dynamical systems.
https://www.researchgate.net/publication/387141113_The_impact_of_AI_on_engineering_design_procedures_for_dynamical_systems
9. Czech Technical University in Prague Faculty of Mechanical Engineering – Department of Designing and Machine Components: ARTIFICIAL INTELLIGENCE SUPPORTED MECHANICAL ENGINEERING DESIGN.
<https://dspace.cvut.cz/bitstream/handle/10467/113801/F2-BP-2024-Akiki-Charbel-Artificial%20intelligence%20supported%20mechanical%20engineering%20design.pdf?sequence=-1&isAllowed=y>
10. Expanding the Classical V-Model for the Development of Complex Systems Incorporating AI. January 2024. IEEE Transactions on Intelligent Vehicles. <https://doi.org/10.1109/TIV.2024.3434515>
11. Application of Computational Kinematics in the Digital Mechanism and Gear Library DMG-Lib.
<http://jc.fauroux.free.fr/PUB/DIVERS/41-CK2005.pdf>
12. MIT Technology Review: The Great Acceleration – CIO Perspectives on Generative AI.
https://www.databricks.com/sites/default/files/2023-07/ebook_mit-cio-generative-ai-report.pdf
13. New IT Driven Service-Oriented Smart Manufacturing: Framework and Characteristics | IEEE Journals & Magazine. <https://ieeexplore.ieee.org/document/8672580>
14. VDI 2206 - A New Guideline for the Design of Mechatronic Systems.
<https://www.sciencedirect.com/science/article/pii/S1474667017340351?via%3Dihub>

15. What is model-based systems engineering (MBSE)? [https://www.ibm.com/think/topics/model-based-systems-engineering#:~:text=Model%2Dbased%20systems%20engineering%20\(MBSE\)%20is%20a%20methodology%20that,validation%20activities%2C%20through%20to%20decommissioning](https://www.ibm.com/think/topics/model-based-systems-engineering#:~:text=Model%2Dbased%20systems%20engineering%20(MBSE)%20is%20a%20methodology%20that,validation%20activities%2C%20through%20to%20decommissioning)
16. AI in Quality Assurance: The Next Big Thing in Quality Management, Apr 11, 2024. <https://www.effivity.com/blog/ai-in-quality-assurance-the-next-big-thing-in-quality-management>
17. AI in Quality: Revolutionizing the QMS Industry, June 5, 2025. <https://www.qualityze.com/blogs/ai-quality-revolutionizing-qms-industry>
18. Yuksel et al, Review of artificial intelligence applications in engineering design perspective, Engineering Applications of Artificial Intelligence, Volume 118, 2023. <https://www.sciencedirect.com/science/article/abs/pii/S095219762200687X?via%3Dihub>
19. Mukhamediev et al, Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges, Mathematics 2022, 10(15), 2552. <https://doi.org/10.3390/math10152552>
20. Germany's Industry 4.0: Innovation and Technology. <https://scaler8.com/insights/germanys-industry-4-0-innovation-and-technology/>
21. Industrial Strategy Building a Britain fit for the future (UK). <https://assets.publishing.service.gov.uk/media/5a8224cbcd915d74e3401f69/industrial-strategy-white-paper-web-ready-version.pdf>
22. Materials and manufacturing vision 2050 (UK). <https://iuk-business-connect.org.uk/wp-content/uploads/2023/03/Innovate-UK-Materials-and-Manufacturing-Vision-2050.pdf>
23. Artificial Intelligence (AI) in Military Market. https://www.marketresearchfuture.com/reports/ai-in-military-market-7660?utm_term=&utm_campaign=&utm_source=adwords&utm_medium=ppc&hsa_acc=2893753364&hsa_cam=20513279457&hsa_grp=153141660637&hsa_ad=672796300975&hsa_src=g&hsa_tgt=dsa-2188716108182&hsa_kw=&hsa_mt=&hsa_net=adwords&hsa_ver=3&gad_source=1
24. Special Issue: Artificial Intelligence and Engineering Design, J. Mech. Des. Feb 2022, 144(2): 020301. <https://doi.org/10.1115/1.4053111>
25. IBM- What is Predictive Maintenance? <https://www.ibm.com/think/topics/predictive-maintenance>
26. Future of Jobs Report 2025. Published: 7 January 2025. https://reports.weforum.org/docs/WEF_Future_of_Jobs_Report_2025.pdf
27. Artificial intelligence in drug development. <https://www.nature.com/articles/s41591-024-03434-4>
28. Application of Artificial Intelligence in Aerospace Engineering and Its Future Directions: A Systematic Quantitative Literature Review. April 2024. https://www.researchgate.net/publication/379867696_Application_of_Artificial_Intelligence_in_Aerospace_Engineering_and_Its_Future_Directions_A_Systematic_Quantitative_Literature_Review
29. The Future of Engineering: Integrating AI into Application Design. 27 Apr 2024. <https://www.iancollmceachern.com/single-post/the-future-of-engineering-integrating-ai-into-application-design>
30. The Future of AI is Real-Time Data. <https://www.striim.com/blog/future-of-ai-real-time-data/>
31. Artificial intelligence (AI): What it is and why it matters. SAS. https://www.sas.com/en_us/insights/analytics/what-is-artificial-intelligence.html

32. What Is Artificial Intelligence (AI)? Definition, Types, Goals, Challenges, and Trends in 2022. Spiceworks.
<https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-ai/>
33. AI-based predictive maintenance - Siemens Global.
<https://www.siemens.com/global/en/products/services/industry/digital-enterprise-services/analytical-services/ai-based-predictive-maintenance.html>
34. AI Case Study Saturday: Predictive Maintenance in Manufacturing - 34 Electric.
<https://www.linkedin.com/pulse/ai-case-study-saturday-predictive-maintenance-manufacturing-ge-/?trackingId=>
35. Exploring the impact of AI in electronic design. April 22, 2024 By Brian Sathianathan.
<https://www.electronicproducts.com/exploring-the-impact-of-ai-in-electronic-design/>
36. AI-driven electronics design. N. Mughees. 20 January 2025.
<https://electronics360.globalspec.com/article/20999/ai-driven-electronics-design>
37. AI in Electronics: The Future of Smart Tech. <https://themetamyths.com/ai-electronics-future-technology/>
38. Review of Machine Learning Techniques for Power Electronics Control and Optimization.
<https://arxiv.org/abs/2310.04699>
39. Generative AI for Electronic Circuit Design – an exploration. April 30, 2024.
https://techexplorations.com/blog/artificial-intelligence/ai-in-circuit-design/?utm_source=chatgpt.com
40. NVIDIA Metropolis. <https://www.nvidia.com/en-eu/autonomous-machines/intelligent-video-analytics-platform/>
41. Introduction to Generative Design for Aerospace Applications: From Creative Process to Manufacturing.
<https://link.springer.com/content/pdf/10.1007/978-3-031-89053-6.pdf>
42. Parankush Koul , A review of machine learning applications in aviation engineering, January 2025, Advances in Mechanical and Materials Engineering 42:16-40 , DOI:10.7862/rm.2025.2
43. EASA Artificial Intelligence Roadmap 2.0 published: A human-centric approach to AI in aviation.
<https://www.easa.europa.eu/en/document-library/general-publications/easa-artificial-intelligence-roadmap-20>
44. EASA Artificial Intelligence Concept Paper Issue 2: Guidance for Level 1 & 2 machine-learning applications. 19 Apr 2024. <https://www.easa.europa.eu/en/document-library/general-publications/easa-artificial-intelligence-concept-paper-issue-2>
45. Cornelius et al, PALMO: An OVERFLOW Machine Learning Airfoil Performance Database,
https://ntrs.nasa.gov/api/citations/20250010353/downloads/palmo_Aagren_print.pdf
46. Automatic Speech Recognition and Understanding in Air Traffic Management. MDPI 2024.
https://elib.dlr.de/203128/1/Automatic_Speech_Recognition_and_Understanding_in_Air_Traffic_Management.pdf
47. Unleashing the Power of AI: Transforming Quality Engineering for the Digital Age.
<https://qentelli.com/thought-leadership/insights/unleashing-the-power-of-ai-transforming-quality-engineering-for-the-digital-age#:~:text=AI's%20role%20in%20managing%20and,achieve%20more%20comprehensive%20test%20coverage>
48. A Systematic Literature Review on Using Natural Language Processing in Software Requirements Engineering.
https://www.researchgate.net/publication/380865266_A_Systematic_Literature_Review_on_Using_Natural_Language_Processing_in_Software_Requirements_Engineering

49. 10 AI Code Review Tools That Find Bugs & Flaws in 2025. By Surbhi. Published: June 18, 2025.
<https://www.digitalocean.com/resources/articles/ai-code-review-tools>
50. An Empirical Study on Learning Bug-Fixing Patches in the Wild via Neural Machine Translation.
<https://dl.acm.org/doi/10.1145/3340544>
51. Continuous Integration, Delivery and Deployment: A Systematic Review on Approaches, Tools, Challenges and Practices.
https://www.researchgate.net/publication/315381994_Continuous_Integration_Delivery_and_Deployment_A_Systematic_Review_on_Approaches_Tools_Challenges_and_Practices
52. The impact of artificial intelligence on the subject of simulation in engineering. February 8th, 2024.
<https://www.techsoft3d.com/resources/blog/ai-is-impacting-engineering-design-simulation/>
53. Physics-informed machine learning. Published: 24 May 2021.
https://www.researchgate.net/publication/351814752_Physics-informed_machine_learning
54. Physics-informed neural networks : A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations.
<https://www.sciencedirect.com/science/article/abs/pii/S0021999118307125>
55. The next innovation revolution—powered by AI. McKinsey. June 20, 2025.
<https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-next-innovation-revolution-powered-by-ai?stcr=BD87777F43544B3D8B1ED5C61E9B00A1&cid=other-eml-alt-mip-mck&hlkid=d69acabc2d264614af33a3e51a89797a&hctky=1618993&hdpid=71f74922-65ff-47fb-9dbb-a20abccfc793#/>
56. MeshingNet: A New Mesh Generation Method Based on Deep Learning. June 2020.
https://www.researchgate.net/publication/342308914_MeshingNet_A_New_Mesh_Generation_Method_Based_on_Deep_Learning
57. Supercharging the industry transformation with the comprehensive Digital Twin.
<https://www.57ens.com/global/en/company/stories/industry/2025/digital-twin-for-industry.html>
58. Artificial Intelligence (AI) for Crash Risk Forecasting During Automotive Crash Simulations. January 2025.
https://www.researchgate.net/publication/390220721_Artificial_Intelligence_AI_for_Crash_Risk_Forecasting_During_Automotive_Crash_Simulations
59. Accelerate automotive crashworthiness with AI. <https://www.noessolutions.com/blog/accelerate-automotive-crashworthiness-with-ai>
60. Machine Learning-Based Crashworthiness Optimization of Crash Box Geometry by Adding Corner Shape Reinforcement Variations. October 2023. <https://doi.org/10.1109/TSSA59948.2023.10366993>
61. Physics-Informed Neural Operator for Learning Partial Differential Equations.
<https://dl.acm.org/doi/10.1145/3648506>
62. Machine learning for molecular and materials science. Nature volume 559, pages 547–555 (2018).
<https://doi.org/10.1038/s41586-018-0337-2>
63. 'Why Should I Trust You?': Explaining the Predictions of Any Classifier. KDD '16.
<https://doi.org/10.1145/2939672.2939778>
64. Engineering Artificial Intelligence: Framework, Challenges, and Future Direction. University of Maryland. 17 Apr 2025. <https://arxiv.org/html/2504.02269v2>
65. Combining Machine Learning and Simulation to a Hybrid Modelling Approach: Current and Future Directions. First Online: 22 April 2020. https://link.springer.com/chapter/10.1007/978-3-030-44584-3_43

66. The Impact of AI on Developer Productivity: Evidence from GitHub Copilot. <https://arxiv.org/pdf/2302.06590>
67. AI in Software Development: Productivity at the Cost of Code Quality. <https://devops.com/ai-in-software-development-productivity-at-the-cost-of-code-quality/>
68. The Effects of Generative AI on High-Skilled Work: Evidence from Three Field Experiments with Software Developers. February 2025. https://economics.mit.edu/sites/default/files/inline-files/draft_copilot_experiments.pdf
69. AI Transforming Human Factors Engineering in Manufacturing. <https://praxie.com/artificial-intelligence-ai-digital-manufacturing-human-factors-engineering/>
70. How to account AI in human factor analysis of complex systems. Process Safety and Environmental Protection. Volume 171, March 2023, Pages 736-750. <https://www.sciencedirect.com/science/article/pii/S0957582023000782#:~:text=Its%20effectiveness%20in%20quantifying%20data%2C%20identifying%20unsafe,complex%20socio%2Dtechnical%20systems%20beyond%20the%20process%20industry>
71. AI in Education: Five Steps to Integrate AI into Your Curriculum. <https://www.hurix.com/blogs/ai-in-education-five-steps-to-integrate-ai-into-your-curriculum/>
72. How AI is Revolutionizing Workplace Ergonomics. By: Jacob Mieso | October 11, 2024. <https://www.tumeke.io/updates/how-ai-is-revolutionizing-workplace-ergonomics#:~:text=The%20primary%20advantage%20of%20AI%2Ddriven%20ergonomics%20is,actions%20to%20create%20a%20safer%20work%20environment>
73. Artificial intelligence and emerging technologies in assessing ergonomic risk factors in the workplace: A systematic review. June 19, 2025. <https://doi.org/10.1177/10519815251349793>
74. Bringing AI techniques to systems engineering. <https://list.cea.fr/en/page/bringing-ai-techniques-to-systems-engineering/>
75. AI in Engineering: Applications, Key Benefits, and Future Trends. <https://www.neuralconcept.com/post/what-is-artificial-intelligence-engineering>
76. AI Product Design: Benefits and Applications. <https://www.neuralconcept.com/post/the-future-of-product-design-ais-impact-on-industries>
77. השפעת הבינה המלאכותית על שוק העבודה והיערכות הנדרשת. המכון לדמוקרטיה. <https://www.idi.org.il/articles/59423>
78. The Application of Artificial Intelligence in Engineering Education: A Systematic Review. <https://ieeexplore.ieee.org/document/10851283>
79. How is AI used in aerospace engineering. https://www.cadence.com/en_US/home/ai/aerospace.html
80. Predictive Maintenance in Aviation using Artificial Intelligence. May 2024. https://www.researchgate.net/publication/383921179_Predictive_Maintenance_in_Aviation_using_Artificial_Intelligence
81. Reliability and Safety Engineering for Safety Critical Systems: An Interview Study With Industry Practitioners. IEEE. <https://ieeexplore.ieee.org/document/9353567>
82. 07/04/2025. דו"ח התעסוקה בהייטק של רשות החדשנות. https://innovationisrael.org.il/press_release/high-tech-employment-report-2025/
83. Predictive Maintenance in Aviation using Artificial Intelligence https://www.researchgate.net/publication/383921179_Predictive_Maintenance_in_Aviation_using_Artificial_Intelligence

84. השפעת הבינה המלאכותית על שוק העבודה והיערכות הנדרשת - המכון לדמוקרטיה.
<https://www.idi.org.il/books/59416>
85. The gen AI skills revolution: Rethinking your talent strategy. August 29, 2024.
<https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-gen-ai-skills-revolution-rethinking-your-talent-strategy?stcr=551B472F6E82486FB4D66439DC80FF9C&cid=other-eml-alt-mip-mck&hlkid=a82a9d2d2d5447f0bc4183865226ef6a&hctky=1618993&hdpid=7dfaf2a6-9ab0-464c-91c7-14d4d92a10f1#/>
86. 2024 מאי טאוב. בינה מלאכותית ושוק העבודה הישראלי. <https://www.taubcenter.org.il/research/ai-labor-market/>
87. Bringing entrepreneurial innovation into engineering: How AI is driving the future of engineering. Gilroy Mathew. <https://www.ust.com/en/insights/bringing-entrepreneurial-innovation-into-engineering-how-ai-is-driving-the-future-of-engineering#:~:text=By%20integrating%20AI%20into%20engineering,reducing%20costs%20and%20development%20time>
88. How Is AI Driving a Revolution in Engineering? June 26, 2025.
<https://engineeringmastersonline.rutgers.edu/articles/how-is-ai-driving-revolution-in-engineering/#:~:text=Artificial%20intelligence%20has%20changed%20the,pre%2Dprogramming%20for%20every%20scenario>
89. AI-DRIVEN FAULT DETECTION AND PREDICTIVE MAINTENANCE IN ELECTRICAL POWER SYSTEMS. February 2025. https://www.researchgate.net/publication/390095870_AI-DRIVEN_FAULT_DETECTION_AND_PREDICTIVE_MAINTENANCE_IN_ELECTRICAL_POWER_SYSTEMS_A_SYSTEMATIC_REVIEW_OF_DATA-DRIVEN_APPROACHES_DIGITAL_TWINS_AND_SELF-HEALING_GRIDS
90. AI-Assisted Condition Monitoring and Fault Diagnosis.
https://www.mdpi.com/journal/sensors/special_issues/QM2AFKR055
91. Fault detection and health monitoring in aeronautics engineering.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC9783385/#:~:text=Fault%20diagnosis%20and%20health%20condition,of%20system%20health%20condition%20monitoring>
92. In-situ piezoelectric sensors for structural health monitoring with machine learning integration.
https://www.sciencedirect.com/science/article/pii/S0957415825000066?srnid=4930179&dgcid=SSRN_redirected_SD#:~:text=Abstract,monitoring%20in%20aeronautical%20composite%20materials
93. A graph placement methodology for fast chip design. June 2021. Nature 594(7862):207-212.
https://www.researchgate.net/publication/352267082_A_graph_placement_methodology_for_fast_chip_design
94. McKinsey Technology Trends Outlook 2024. AI Edge Computing Market Outlook.
<https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-top-trends-in-tech-2024>
95. General AI. <https://www.interaction-design.org/literature/topics/general-ai>
96. What is artificial general intelligence? (AWS). <https://aws.amazon.com/what-is/artificial-general-intelligence/#:~:text=and%20AGI%20efforts?-What%20is%20artificial%20general%20intelligence,theoretical%20concept%20and%20research%20goal>
97. What is artificial general intelligence (AGI)? (Google). <https://cloud.google.com/discover/what-is-artificial-general-intelligence>
98. Design for Manufacturing (DFM): A Guide to Optimizing Product Development. October 18th, 2024.
<https://www.6sigma.us/six-sigma-in-focus/design-for-manufacturing-dfm/>

99. The Convergence of Design and Manufacturing: A New Era for the Development of Automotive Optics. <https://www.jabil.com/blog/convergence-design-manufacturing-automotive-optics.html#:~:text=One%20of%20the%20strongest%20value%20propositions%20of,making%20the%20overall%20manufacturing%20process%20more%20efficient>
100. Design for X (DFX) Methods. <https://fractory.com/design-for-x-dfx/>
101. The Impact of Generative AI in the Aerospace Industry: Applications, Benefits, and Future Trends. <https://www.einfochips.com/blog/the-impact-of-generative-ai-in-the-aerospace-industry-applications-benefits-and-future-trends/#:~:text=Gen%20AI%20can%20create%20a,reviewed%20to%20detect%20any%20problem>
102. Artificial Intelligence in Quality Control Systems: A Cross-Industry Analysis. December 2024. https://www.researchgate.net/publication/386595102_Artificial_Intelligence_in_Quality_Control_Systems_A_Cross-Industry_Analysis_of_Applications_Benefits_and_Implementation_Frameworks
103. Wang, F.-Y. (2023). New control paradigm for Industry 5.0: From big models to foundation control and management. <https://doi.org/10.1109/JAS.2023.123768>
104. Hütten, N., et al. (2024). Deep Learning for Automated Visual Inspection in Manufacturing and Maintenance. <https://www.mdpi.com/2571-5577/7/1/11>
105. Törngren, M., et al. (2021). Industrial Edge-based Cyber-Physical Systems. <https://ieeexplore.ieee.org/document/9709084>
106. AI on Chips: How Artificial Intelligence Is Revolutionizing RTL Designing. Umakshi Sharma, July 12, 2025. <https://medium.com/@kaushik.umakshi/ai-on-chips-how-artificial-intelligence-is-revolutionizing-rtl-designing-and-the-semiconductor-6ae3bdcecdc1>
107. What is digital-twin technology? McKinsey, August 26, 2024. <https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-is-digital-twin-technology>
108. How AI is Transforming Additive Manufacturing. <https://www.neuralconcept.com/post/how-ai-is-transforming-additive-manufacturing#:~:text=One%20of%20AI's%20primary%20advantages,efficient%20and%20cost%20effective%20production>
109. The influence of artificial intelligence and additive manufacturing on sustainable manufacturing practices. <https://www.sciencedirect.com/science/article/pii/S2666188825003855#:~:text=AI%20enhances%20design%20optimization%2C%20facilitates,the%20development%20cycle%20%5B50%5D>
110. DoD Additive Manufacturing Strategy. <https://www.cto.mil/dod-additive-manufacturing-strategy/>
111. Department of Defense Additive Manufacturing Strategy. January 2021. <https://www.cto.mil/wp-content/uploads/2021/01/dod-additive-manufacturing-strategy.pdf>
112. National Academies of Sciences, Engineering, and Medicine. 2025. Artificial Intelligence and the Future of Work. <https://doi.org/10.17226/27644>
113. National Academies of Sciences, Engineering, and Medicine. 2022. Human-AI Teaming: State-of-the-Art and Research Needs. <https://doi.org/10.17226/26355>
114. How AgentEngineer™ Technology Will Transform Engineering Workflows. Sassine Ghazi. May 06, 2025. <https://www.synopsys.com/blogs/chip-design/agentengineer-technology-transforming-engineering-workflows.html>

115. These human capabilities complement AI's shortcomings. By Brian Eastwood. June 10, 2025.
https://mitsloan.mit.edu/ideas-made-to-matter/these-human-capabilities-complement-ais-shortcomings?utm_medium=email&msgid=613964&subscriberid=224296645&subscriberkey=003U100000HodYMAZ&utm_source=course-promotion&utm_campaign=manual_2025-08-20_human-skills-ai&utm_content=cj:aw_1a_uo&ctype=mkt
116. Machine Learning for Fluid Mechanics. January 2020.
https://www.researchgate.net/publication/335785608_Machine_Learning_for_Fluid_Mechanics
117. What is Computational Fluid Dynamics (CFD)? <https://www.ansys.com/simulation-topics/what-is-computational-fluid-dynamics#:~:text=New%20Energy%20As%20an%20enabler,consumption%2C%20and%20fuel%20cell%20utilization>
118. What is KRR (Knowledge Representation and Reasoning)? [https://www.oxfordsemantic.tech/faqs/what-is-krr-knowledge-representation-and-reasoning#:~:text=Knowledge%20Representation%20and%20Reasoning%20\(KRR\)%20is%20a,a%20form%20that%20a%20computer%20can%20understand](https://www.oxfordsemantic.tech/faqs/what-is-krr-knowledge-representation-and-reasoning#:~:text=Knowledge%20Representation%20and%20Reasoning%20(KRR)%20is%20a,a%20form%20that%20a%20computer%20can%20understand).
119. Artificial intelligence (AI) vs. machine learning (ML) <https://cloud.google.com/learn/artificial-intelligence-vs-machine-learning>
120. What is NLP? [https://www.ibm.com/think/topics/natural-language-processing#:~:text=Natural%20language%20processing%20\(NLP\)%20is,Apple's%20Siri%20and%20Microsoft's%20Cortana](https://www.ibm.com/think/topics/natural-language-processing#:~:text=Natural%20language%20processing%20(NLP)%20is,Apple's%20Siri%20and%20Microsoft's%20Cortana).
121. Expert System <https://www.techtarget.com/searchenterpriseai/definition/expert-system#:~:text=Expert%20systems%20accumulate%20experience%20and%20facts%20in,base%20to%20situations%20provided%20to%20the%20program.&text=It%20is%20a%20rules%2Dbased%20system%20that%20maps,and%20makes%20decisions%20based%20on%20those%20inputs>.
122. Metaheuristic Evolutionary Algorithms: Types, Applications, Future Directions, and Challenges
<https://ieeexplore.ieee.org/document/10205592>
123. Digital Twins and AI: Real-Time Simulation of Complex Systems
https://www.researchgate.net/publication/392966343_Digital_Twins_and_AI_Real-Time_Simulation_of_Complex_Systems
124. Fuzzy logic and probability <https://arxiv.org/pdf/1302.4953>
125. Multi Agent Systems <https://www.sciencedirect.com/topics/computer-science/multi-agent-systems#:~:text=Multi%2DAgent%20Systems%20in%20Computer%20Science%20refer%20to,and%20perform%20actions%20consistently%20to%20optimize%20outcomes>.
126. OpenAI. (2023). GPT-4 technical report. Retrieved from <https://openai.com/research>
127. Digital Twin in Industry: State-of-the-Art <https://ieeexplore.ieee.org/document/8477101>
128. System of Systems Integration: Key Considerations and Challenges September 2014. Systems Engineering17(3)
129. DOI: [10.1002/sys.21272](https://doi.org/10.1002/sys.21272)
https://www.researchgate.net/publication/259543357_System_of_Systems_Integration_Key_Considerations_and_Challenges
130. Ultimate Guide to Systems Integration Risk Management and Systems Engineering Best Practices
<https://www.numberanalytics.com/blog/ultimate-guide-systems-integration>
131. Chen, M., Tworek, J., Jun, H., et al. (2021). *Evaluating Large Language Models Trained on Code*. arXiv preprint arXiv:2107.03374. <https://arxiv.org/abs/2107.03374>

132. Natural Language Processing for Requirements Engineering: A Systematic Mapping Study.
https://pure.manchester.ac.uk/ws/portalfiles/portal/183513868/2020_12_16_NLP4RE_Accepted.pdf
133. Pearce, H., Ahmad, T., Mendis, C., & Ceze, L. (2022). *Asleep at the Keyboard? Assessing the Security of GitHub Copilot's Code Contributions*. IEEE Symposium on Security and Privacy.
<https://arxiv.org/abs/2108.09293>
134. Tufano, M., Watson, C., Bavota, G., et al. (2020). *An empirical study on learning bug-fixing patches in the wild via neural machine translation*. ACM Transactions on Software Engineering and Methodology (TOSEM), 29(4), 1-29.
135. <https://dl.acm.org/doi/10.1145/3340544>
136. Shahin, M., Babar, M. A., & Zhu, L. (2017). Continuous integration, delivery and deployment: A systematic review on approaches, tools, challenges and practices. IEEE Access, 5, 3909–3943.
https://www.researchgate.net/publication/315381994_Continuous_Integration_Delivery_and_Deployment_A_Systematic_Review_on_Approaches_Tools_Challenges_and_Practices
137. AI that builds with you. <https://github.com/features/copilot>
138. 10 AI Code Review Tools That Find Bugs & Flaws in 2025 By [Surbhi](#). Published: June 18, 2025
<https://www.digitalocean.com/resources/articles/ai-code-review-tools>
139. How AI is Revolutionizing Software Development by Katerina Trajchevska. 2024
140. <https://adevait.com/artificial-intelligence/impact-of-ai-on-software-development>
141. Integrating single-cell transcriptomic data across different conditions technologies, and species
[Andrew Butler](#), [Paul Hoffman](#), [Peter Smibert](#), [Efthymia Papalexi](#) & [Rahul Satija](#)
<https://pmc.ncbi.nlm.nih.gov/articles/PMC6700744/>
<https://pmc.ncbi.nlm.nih.gov/articles/PMC6700744/pdf/nihms-990262.pdf>
142. Source: Combining Machine Learning and Simulation to a Hybrid Modelling Approach: Current and Future Directions
https://link.springer.com/chapter/10.1007/978-3-030-44584-3_43
143. All You Need to Know About Software Design Process
<https://www.sparxitsolutions.com/blog/software-design-process/>
144. How AI Is Transforming Supply Chain Management
<https://www.penskelogistics.com/technology/keep-supply-chain-moving/ai-in-supply-chain-management/>
145. The Role of AI in Supply Chain Optimization
<https://www.ucumberlands.edu/blog/role-ai-supply-chain-optimization>
146. Sustainability by Design: How AI Helps Architects Build Greener, Smarter Structures.
[Stealthtech365.com](#)
147. Sustainable Engineering Initiative
<https://engineering.nyu.edu/impact/sustainability/sustainable-engineering-initiative>
148. The Impact of AI on the Engineering Field
Johns Hopkins University – Whiting School of Engineering
Published: June 14, 2024
<https://ep.jhu.edu/news/the-impact-of-ai-on-the-engineering->

[field/#:~:text=For%20engineers%20working%20with%20design,priorities%20for%20manufacturers%20and%20consumers.](#)

149. Airbus Annual Report 2023 <https://www.airbus.com/sites/g/files/jlcbta136/files/2024-03/Airbus-Annual-Report-2023.pdf>
150. Barak Or , Improving Requirements Classification with SMOTE-Tomek Preprocessing, January 2025, DOI: 10.48550/arXiv.2501.06491
151. Oz Levi et al, Work in Progress: AI-Powered Engineering-Bridging Theory and Practice. , March 2025. DOI: 10.1109/EDUNINE62377.2025.10981330, https://www.researchgate.net/publication/391469102_Work_in_Progress_AI-Powered_Engineering-Bridging_Theory_and_Practice
152. Human-in-the-Loop AI in Model-Based Systems Engineering Turbocharges Defense Manufacturing , <https://blog.3ds.com/brands/catia/ai-in-model-based-systems-engineering/>
153. Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045> <https://www.sciencedirect.com/science/article/abs/pii/S0021999118307125>
154. 158. Kenett, Ron S. and Davis, Tim, The Role of AI in Engineering: An Overview (January 01, 2025). Available at SSRN: <https://ssrn.com/abstract=5081242> or <http://dx.doi.org/10.2139/ssrn.5081242>
155. Zhu, Y., & Zabarar, N. (2018). Bayesian deep convolutional encoder–decoder networks for surrogate modeling and uncertainty quantification. *Journal of Computational Physics*, 366, 415–447. <https://doi.org/10.1016/j.jcp.2018.04.018> <https://www.sciencedirect.com/science/article/pii/S0021999118302341?via%3Dihub>
156. Finite-Element Mesh Generation Using Self-Organizing Neural Networks Larry Manevitz, Malik Yousef, Dan Givoli. https://www.researchgate.net/publication/229544455_Finite-Element_Mesh_Generation_Using_Self-Organizing_Neural_Networks
157. What's the Situation with Intelligent Mesh Generation: A Survey and Perspectives Na Lei, Zezeng Li, Zebin Xu, Ying Li, and Xianfeng Gu. 2022 <https://arxiv.org/pdf/2211.06009>
158. CAPABILITIES OF AI IN TEXT-TO-3D MODEL GENERATORS FOR MECHANICAL COMPONENTS DESIGN November 2024 DOI: 10.24867/GRID-2024-p44 https://www.researchgate.net/publication/385464484_CAPABILITIES_OF_AI_IN_TEXT-TO-3D_MODEL_GENERATORS_FOR_MECHANICAL_COMPONENTS_DESIGN
159. Digital Twins: Strategic and Methodological Aspects https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5213512
160. Building and comparing models of user interfaces for air traffic control DOI: [10.1109/DASC.2004.1390807](https://doi.org/10.1109/DASC.2004.1390807)
161. Engineering Psychology and Human Performance DOI: <https://doi.org/10.4324/9781315665177>
162. Topol, E. J. (2019). *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.
163. How AI is Revolutionizing Workplace Ergonomics By: Jacob Mieso | October 11, 2024 ([SOURCE](#))
164. Artificial intelligence and emerging technologies in assessing ergonomic risk factors in the workplace: A systematic review. June 19, 2025 ([SOURCE](#))
165. <https://www.digitalengineering247.com/download/january-special-focus-issue-design-for-additive>



neaman.org.il

מוסד שמואל נאמן למחקר מדיניות לאומית | קרית הטכניון,
חיפה 3200003 | טל. 04-8292329 | info@neaman.org.il

חינוך מהנדסים