Modern Physics 现代物理, 2026, 16(6), 234-245
Published Online November 2026 in Hans. https://www.hanspub.org/journal/mp
https://doi.org/10.12677/mp.2026.166025

Hans汉斯

人工智能时代的信息物理学与智能信息演化

贺方俊

贵州大学大数据与信息工程学院，贵州 贵阳

收稿日期：2026年10月4日；录用日期：2026年10月26日；发布日期：2026年11月3日

摘　要

信息物理学关注信息与物理状态、计算过程和智能行为之间的关系。信息这一概念经历了从经典物理中的状态描述、Shannon信息论中的统计表征，到人工智能时代语义表示的发展过程。本文从信息物理学视角出发，讨论信息产生、表示、传输和利用过程中物理规律与智能信息处理之间的关系，重点关注信息如何由物理状态经过观测和数据处理形成语义表示，并进一步服务于具体智能任务。以自动驾驶感知决策系统为贯穿案例，本文系统讨论信息从物理状态、统计表征到语义信息的演化过程——从传感器获取的物理信号，到深度学习识别和表示的行人、车辆等语义对象，再到驾驶决策。在此基础上，分析人工智能在信息表示、知识形成和生成式处理中的作用，以语义通信为例讨论信息如何从物理观测经智能表示服务于任务决策，并探讨信息价值描述以及人工智能与物理规律融合等方向。分析表明，人工智能时代的信息科学正在由“描述信息”逐步扩展到“理解信息”和“利用信息”，而信息物理学视角强调信息演化过程受到物理观测条件、计算实现和任务需求的共同影响。

关键词

信息演化，人工智能，物理基础，语义信息，智能系统

Information Physics and Intelligent Information Evolution in the Age of Artificial Intelligence

Fangjun He

College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

Received: October 4, 2026; accepted: October 26, 2026; published: November 3, 2026

Abstract

Information physics focuses on the relationship among information, physical states, computational

文章引用: 贺方俊. 人工智能时代的信息物理学与智能信息演化[J]. 现代物理, 2026, 16(6): 234-245.
DOI: 10.12677/mp.2026.166025

processes, and intelligent behaviors. The concept of information has evolved from the description of physical states in classical physics, to the statistical representation in Shannon information theory, and further to semantic representations in the era of artificial intelligence. From the perspective of information physics, this paper discusses the relationships between physical laws and intelligent information processing during the generation, representation, transmission, and utilization of information. Particular attention is given to how information evolves from physical states into semantic representations through observation and data processing, and further supports specific intelligent tasks. Taking an autonomous driving perception-decision system as a representative case, this paper systematically analyzes the evolution of information from physical states and statistical representations to semantic information, covering the process from physical signals acquired by sensors, to semantic objects such as pedestrians and vehicles recognized and represented by deep learning models, and ultimately to driving decisions. Furthermore, the roles of artificial intelligence in information representation, knowledge formation, and generative processing are analyzed. Using semantic communication as an example, this paper discusses how information is transformed from physical observations into intelligent representations to support task-oriented decision-making, and explores future directions including information value characterization and the integration of artificial intelligence with physical laws. The analysis indicates that information science in the era of artificial intelligence is gradually evolving from "describing information" toward "understanding information" and "utilizing information". From the perspective of information physics, the evolution of information is jointly influenced by physical observation conditions, computational implementations, and task requirements.

Keywords

Information Evolution, Artificial Intelligence, Physical Foundations, Semantic Information, Intelligent Systems

Copyright © 2026 by author(s) and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).
http://creativecommons.org/licenses/by/4.0/
Open Access

1. 引言

信息是连接物理世界、数据表示和智能认知的重要概念。从对物理系统状态的描述，到 Shannon 信息论中对随机事件不确定性的统计表征，再到人工智能系统中的语义表示和任务相关信息，信息的内涵和研究范畴随着科学技术的发展不断扩展。本文所讨论的信息物理学视角认为，信息并非独立于物理世界存在的抽象符号，而是依托物理状态产生，并在观测、计算和表示过程中形成的一种表征形式。该视角关注信息产生、存储、处理和利用过程中物理状态、计算过程与智能行为之间的相互作用，强调信息既受到物理实现条件的约束，也能够通过不同层次的表示影响系统行为。对于实际智能系统而言，信息通常来源于对真实物理环境的观测，并经过采集、量化、计算和表示等过程逐步转化为能够支持识别、预测和决策的信息。因此，理解信息从物理状态到数据表示，再到语义认知和智能决策的演化过程，以及这一过程中涉及的物理基础和信息处理机制，对于认识人工智能时代的信息系统具有重要意义。

Shannon 于 1948 年提出的信息论，为现代信息科学建立了严格的数学基础[1]。通过信息熵、互信息和信道容量等概念，Shannon 理论从概率统计角度刻画了信息的不确定性及其在通信系统中的传输规律，并为数据压缩和可靠通信奠定了理论基础。然而，Shannon 信息论主要处理信息的统计属性和传输问题，并不以消息语义内容以及任务有效性作为主要研究目标。因此，Shannon 信息论主要回答“信息如何被量化以及如何可靠传输”的问题，而信息物理学视角进一步关注信息如何依托物理世界产生，并如何经过

处理影响系统行为。随着信息系统逐渐由数据传输扩展到环境感知、智能分析和任务决策，信息研究也开始进一步关注信息的物理来源、表示方式以及任务相关性。

物理学与计算科学的发展进一步揭示了信息处理与物理过程之间的联系。Landauer 原理指出，逻辑不可逆的信息处理与热耗散之间存在基本联系，说明信息处理虽然可以在数学和算法层面进行抽象，但其实际实现仍依赖具体的物理过程，并受到热力学规律约束[2]。量子信息研究则进一步表明，信息可以通过量子态等物理载体进行编码、存储和处理，并受到相应物理规律的约束[3]。这些研究说明，信息的存储、处理和传输具有具体的物理实现基础。其中，计算热力学主要研究信息处理过程中的逻辑操作、能量耗散和热力学极限，而本文的信息物理学视角进一步关注信息从物理状态产生、经过表示和计算，并最终服务智能任务的全过程。

人工智能的发展进一步改变了信息的表示和利用方式。深度学习、Transformer 以及大规模模型和生成模型能够从复杂数据中自动提取特征、学习上下文关系和数据分布，使信息处理逐渐由对原始数据的直接操作拓展到高层表示、语义建模和生成式恢复。从信息物理学视角看，大模型中的信息处理可以理解为信息在不同表示空间之间的转换过程，而这一过程依赖计算硬件提供的物理资源。在这一过程中，信息可以由传感器获得的原始观测逐步转化为与识别、预测和决策相关的表示。与此同时，这些算法过程最终仍需要由具体计算硬件实现，涉及计算、存储访问和数据传输等物理过程，并伴随相应的计算资源和能量消耗。因此，人工智能时代的信息演化不仅涉及信息表示层次的变化，也与信息处理所依赖的物理实现密切相关。

除 Shannon 信息论外，算法信息论、控制论和神经符号人工智能也分别从不同角度研究信息。算法信息论中的 Kolmogorov 复杂度通过生成一个对象所需的最短程序长度刻画其描述复杂度，为从计算角度理解信息提供了重要理论工具[4]。控制论强调信息在反馈和调节过程中的作用，关注系统如何根据获得的信息调整自身状态和行为[5]。神经符号人工智能则通过符号、规则和逻辑关系进行知识表示和推理，为结构化知识表达和智能推理提供了重要方法[6]。这些理论分别从统计度量、描述复杂度、反馈控制和知识表示等不同层面讨论信息。人工智能系统则进一步将物理感知、数据处理、语义表示和任务决策连接起来，使不同层次的信息研究在实际智能系统中形成更加紧密的联系。

语义通信的发展进一步体现了信息处理由数据可靠传输向语义和任务相关信息利用的拓展。传统通信主要关注发送端数据能否经过信道可靠地传递至接收端，而语义通信进一步关注传输过程中能否保持信息所承载的意义，以及这些信息能否有效支持后续任务[7]。随着人工智能方法应用于通信系统，语义提取、信息传输和任务执行之间的联系进一步增强，使通信系统的目标由数据层面的准确恢复逐渐扩展到语义保持和任务有效性。语义通信因此为观察信息如何从物理环境出发，经过智能表示和通信过程最终服务于实际任务提供了一个典型实例。为了具体说明这一信息演化过程，本文以自动驾驶感知与决策系统作为贯穿全文的典型案例。在真实道路环境中，车辆、行人、交通标志及其位置和运动状态首先构成待感知的物理状态；摄像头、激光雷达和毫米波雷达分别通过相应的物理观测过程获取环境信息，并形成图像、点云和雷达回波等原始数据；这些观测数据经过量化、预处理和特征提取后，可形成目标位置、距离、速度以及空间关系等数据和统计特征；人工智能模型进一步从中提取和表示“车辆”“行人”“车道线”和“交通标志”等语义对象；最终，感知结果与车辆自身状态和驾驶任务相结合，用于路径规划、加速、减速、制动或避让等决策。由此，自动驾驶系统中的信息演化过程可以概括为：物理状态→传感器观测→数据与统计特征→语义表示→任务决策与控制。这一过程还说明，不同信息对最终任务具有不同作用。例如，前方行人的位置、距离和运动方向可能直接影响车辆是否需要制动，而远离行驶区域的部分背景细节通常不会对当前驾驶决策产生同等程度的影响。因此，在面向智能任务的信息系统中，除了关注信息的统计特征和传输可靠性之外，还需要进一步考虑信息与具体物理环境、语义表示和任务

目标之间的关系。

基于上述背景，本文围绕人工智能时代的信息物理学与智能信息演化展开讨论。首先介绍信息与物理状态之间的关系以及从统计信息到语义信息的发展过程；随后讨论深度学习、大规模模型和生成模型对信息表示与恢复方式的影响，并分析人工智能信息处理与物理计算实现之间的联系；然后以语义通信为例，讨论信息如何由物理观测经过智能表示、传输和恢复进一步服务于任务决策；同时结合算法信息论、控制论和神经符号人工智能等相关理论，对不同的信息描述与利用方式进行比较；最后讨论信息价值描述、人工智能与物理规律融合以及未来智能信息系统的发展方向。

2. 信息的物理基础与理论演化

2.1. 信息、物理状态与信息形成

在实际信息系统中，信息的产生、存储、处理和传输均需要依托具体的物理过程和物理载体。从微观粒子的状态、晶体中的缺陷分布，到计算机存储器中的电子状态以及生物神经系统中的电化学活动，不同形式的信息都需要通过相应的物理状态进行记录和处理。然而，信息并不等同于物理状态本身，而是物理状态中可被观测、编码和表示的特征，通过相应的信息处理过程形成可用于描述、预测或控制的信息结构。因此，对信息的研究不仅涉及抽象的数据和符号，也与这些信息产生和实现所依赖的物理过程密切相关。

早期物理学主要关注物质和能量的变化规律，而统计物理的发展进一步建立了宏观状态与微观状态之间的统计联系。在统计力学中，Boltzmann 熵通过微观状态数描述系统的统计性质，这一思想也构成了后来理解统计熵与信息熵之间联系的重要物理背景[8]。这一发展体现了信息描述逐渐从物理状态本身扩展到状态的不确定性表征。随后，Shannon 将概率方法引入通信问题，通过信息熵、互信息等数学工具刻画随机变量的不确定性及其统计关联，使信息获得了独立于具体物理载体的数学描述[1]。

随着计算技术的发展，信息处理的物理实现问题受到进一步关注。Landauer 原理指出，逻辑不可逆的信息操作与最低热耗散之间存在基本联系，说明算法层面的信息处理最终仍需要通过具体的物理过程实现[2]。在此基础上，可逆计算和计算热力学等研究进一步讨论了逻辑操作、信息擦除、能量耗散以及计算物理极限之间的关系[2]。这些研究主要关注信息处理过程中的能量代价和物理极限，而人工智能时代的信息系统进一步涉及信息如何由真实环境中的物理状态经过观测和计算形成高层表示，并最终参与识别和决策。

以自动驾驶系统为例，道路中的行人、车辆及其位置和运动状态首先属于真实物理环境的一部分。摄像头通过光学成像形成像素数据，激光雷达通过光脉冲传播和回波测量形成点云，毫米波雷达则根据电磁波反射获得目标距离和速度等信息。这些传感器输出首先是对物理环境的观测结果，经过量化、预处理和特征提取后，才进一步形成可以被计算系统分析的数据表示，并为后续的语义识别和驾驶决策提供基础。因此，信息的形成并非单纯的数据采集，而是物理状态经过观测、编码和表示后形成可被计算系统利用的信息结构。

2.2. Shannon 信息论：信息的统计描述

20 世纪中期，随着通信技术的发展，如何定量描述和可靠传输信息成为重要科学问题。1948 年，Shannon 提出信息论，通过概率模型建立了信息不确定性和通信传输的数学描述，为现代通信、数据压缩和编码理论奠定了理论基础[1]。

对于离散随机变量 X ，Shannon 熵定义为：

$$H(X)=-\sum_{x}p(x)\log p(x) \tag{1}$$

其中，$p(x)$表示随机变量X取值为x的概率。信息熵用于衡量随机变量整体的不确定程度；一般而言，概率分布越难预测，其熵越大。进一步地，两个随机变量X和Y之间的互信息可表示为：

$$I(X;Y)=H(X)-H(X|Y) \tag{2}$$

其中，$H(X|Y)$表示在已知Y条件下X的剩余不确定性。互信息刻画了X与Y之间共享的信息量；在通信场景中，可以用于衡量接收端观测Y中保留了多少关于发送端变量X的信息。基于熵、互信息等概念，Shannon 进一步建立了信道容量等理论，为给定信道条件下可靠通信的基本极限提供了数学描述[1]。

Shannon 信息论使信息获得了严格的统计描述，并推动了现代通信和数据压缩理论的发展。然而，其核心研究对象主要是信息的统计不确定性及传输规律，而消息本身所表达的语义以及不同信息对于具体任务的作用并不是其直接研究目标。对于智能系统而言，统计信息量与任务重要性并不总是一致。例如，在自动驾驶图像中，大量道路背景像素可能具有丰富的统计变化，而位于较小区域内的行人目标虽然只占据有限数据，却可能直接影响车辆是否需要减速或制动。因此，统计信息量本身不能完全描述信息对于具体智能任务的重要程度，这也引出了对语义信息和任务相关信息的进一步研究。

2.3. 从统计信息到任务相关语义信息

信息除了可以从统计不确定性的角度进行描述，还涉及观测内容所表达的语义以及其对任务的作用。1949 年，Weaver 在讨论通信问题时将其区分为技术、语义和有效性三个层次[9]。其中，技术层关注通信符号能否准确传输，语义层关注传输符号能否准确表达预期含义，而有效性层则关注接收到的信息能否产生预期作用。

Shannon 信息论主要为技术层的信息传输问题建立了严格的数学基础，而语义层和有效性层则进一步涉及信息所表达的内容及其实际作用。Bar-Hillel 和 Carnap 随后从逻辑和哲学角度研究语义信息，对语义内容及其信息度量进行了讨论[10]。这些研究表明，统计信息与语义信息关注的是信息描述的不同层面：前者主要描述随机变量的不确定性和统计关联，后者进一步关注信息所表达的内容及其解释。

人工智能的发展为从复杂观测数据中形成高层语义表示提供了新的技术手段。在自动驾驶系统中，同一物理观测经过进一步处理后，可形成与任务相关的语义表示。例如，传感器数据中的像素、点云和距离信息经过人工智能模型处理后，可以进一步转化为“车辆”“行人”和“交通标志”等语义对象，并用于后续驾驶决策。因此，对于本文所讨论的智能系统，可以按照：物理状态→传感器观测→数据与统计特征→语义信息→智能决策。

这一过程理解信息表示层次的演化。其中，物理状态是信息产生的客观基础，传感器观测将物理状态转换为可处理的数据，统计分析和特征提取进一步形成结构化表示，而人工智能模型则在此基础上提取与具体任务相关的语义信息。需要指出的是，这种逐层表示并不意味着数据量必然持续减少，也不意味着信息价值必然单调增加，其核心变化在于信息处理逐渐从对原始物理观测的直接记录，发展到对统计结构、语义内容和任务相关信息的提取与利用。这也为后续讨论人工智能驱动的信息表示、大规模模型和生成式信息处理奠定了基础。

3. 人工智能时代的信息表示与演化

3.1. 表征学习：从数据到信息结构

传统信息处理方法通常依赖人工设计的特征和规则，将复杂数据转换为可分析的表示形式。然而，随着数据规模和复杂程度不断增加，人工设计的特征难以充分描述隐藏在高维数据中的复杂结构。例如，

在图像、语音和自然语言等非结构化数据中，与具体任务相关的信息往往分布于局部特征、空间关系以及上下文联系之中。

深度学习的发展改变了这一信息表示方式。由多个处理层构成的深度神经网络能够通过训练学习不同层次的数据表示，并逐渐形成由低层特征到高层抽象表示的层次结构[11]。从数学上看，这一过程可以概括为输入数据到特征空间的非线性映射：

$$z = f_\theta(x) \tag{3}$$

其中，x 表示原始数据，z 表示经过模型提取后的高维特征表示，f_θ 表示由网络参数决定的非线性映射。与人工预先指定全部特征不同，表征学习能够根据训练数据和任务目标自动调整模型内部表示，使其逐渐突出有利于后续识别、预测或决策的信息。

在视觉识别中，这种层次化表示尤其明显。模型可以由局部边缘、纹理和形状等低层视觉特征，逐步形成与物体类别和空间关系相关的高层表示。需要指出的是，这一过程并不意味着模型必须完整保留原始输入中的所有像素细节，也不意味着特征维度一定逐层降低，其主要作用是重新组织输入数据中的信息，使模型表示更加适用于具体任务。这种变化更多体现为信息结构的重新组织，而非简单的信息丢失。从信息物理学视角看，表征学习并不是简单的数据压缩过程，而是通过计算过程重新组织输入观测中的信息结构，使其更加适用于特定任务。

以自动驾驶视觉感知为例，车载摄像头获得的图像首先记录道路环境中的光学观测结果，其中同时包含车辆、行人、道路、建筑及大量背景信息。经过神经网络的多层处理，模型可以逐渐提取边缘、纹理、局部结构以及物体级特征，并进一步识别车辆、行人和车道线等与驾驶任务相关的对象。由此，信息表示由原始观测数据逐渐转化为能够支持环境理解和驾驶决策的结构化特征，这体现了人工智能对信息表示方式的重要改变。

3.2. 大规模模型：从特征表示到知识表征

随着模型规模、训练数据和计算能力不断发展，人工智能系统处理信息的能力由局部特征提取进一步扩展到复杂关系和上下文表示。Transformer 利用注意力机制直接建模输入元素之间的关联，使模型能够根据上下文动态组织不同位置的信息[12]。从信息演化角度看，注意力机制可以被理解为对输入信息之间关联关系的动态重组，使模型能够根据上下文调整不同信息成分的贡献，并逐渐形成更加抽象的内部表示。其基本的缩放点积注意力可以表示为：

$$\mathrm{Attention}(Q,K,V) = \mathrm{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \tag{4}$$

其中，Q,K,V 分别表示查询、键和值矩阵，d_k 表示特征维度。注意力机制通过计算输入表示之间的关联，使模型能够建立不同信息之间的上下文联系。随后，BERT 等预训练模型进一步表明，大规模预训练能够形成上下文相关的内部表示，并通过下游任务适配用于不同自然语言处理任务[13]。

在自动驾驶系统中，不同时间、不同位置以及不同传感器获得的信息之间同样存在复杂联系。例如，单幅图像中检测到的行人位置需要结合车辆速度、目标运动状态以及周围道路环境才能进一步判断其潜在风险。从方法上看，注意力机制所具有的关系建模能力为组织这类上下文相关信息提供了一种能够动态调整信息关联关系的表示机制，使系统能够从孤立的局部特征进一步形成包含空间、时间和对象关系的信息表示，并将这些表示用于后续感知与决策。

人工智能模型中的信息处理同时具有具体的物理实现基础。神经网络的前向传播和训练在算法层面表现为矩阵运算、特征传递和参数更新，而在实际计算系统中，这些操作需要通过处理器运算、存储器

访问以及不同存储层级之间的数据传输来完成。深度神经网络硬件研究表明，计算量和数据移动均会带来实际的能量开销，因此模型的信息处理能力与其计算和存储资源消耗之间存在直接联系[14]。

这种联系需要与热力学层面的信息处理加以区分。类似于物理系统中状态演化需要消耗能量，大规模模型中的信息表示和参数更新也依赖计算资源和能量供给。然而，这种计算资源消耗并不等同于热力学意义上的信息熵变化而是信息处理过程在实际物理系统中的计算和能量代价。前文讨论的 Landauer 原理揭示了逻辑不可逆信息操作与最低热耗散之间的基本关系[2]，而深度神经网络在现实硬件上的实际能耗还受到芯片架构、存储层级、数据移动以及计算方式等多种因素影响[14]。因此，大规模模型中的“信息流动”与“能量消耗”可以分别从算法表示和物理实现两个层面理解，但不能将神经网络的前向传播、反向传播直接等同于特定的热力学过程。这一关系说明，随着模型规模扩大，对信息表示能力的讨论还需要同时关注实现这些计算过程所需要的物理资源。

3.3. 生成模型：从确定恢复到概率化信息表示

除了改变信息表示方式之外，人工智能的发展也改变了信息恢复和重建方式。传统信息处理通常希望根据已有观测尽可能准确地恢复目标状态。然而，在许多复杂问题中，有限观测并不足以唯一确定原始状态，同一观测结果可能对应多个合理解，因此信息恢复过程本身可能具有非唯一性和不确定性。

生成模型为处理这类问题提供了新的思路。以生成对抗网络(GAN) [15]和扩散模型(Diffusion Model) [16]为代表，通过学习数据的概率分布生成满足统计规律的新样本。其中，GAN 通过生成器与判别器之间的对抗训练学习数据分布，扩散模型则通过逐步加噪和反向去噪过程学习复杂数据的生成机制。与寻找单一确定结果的方法不同，生成模型通常试图学习数据的概率分布或条件概率分布。例如，在给定条件 c 的情况下，可以将生成过程描述为学习：$p\left(x|c\right)$。其中，x 表示可能生成的数据状态，c 表示给定的条件、观测或任务信息。通过这一概率化描述，系统可以表示在已有信息条件下存在的不同可能结果。值得注意的是，这种概率化生成并不意味着模型生成的所有结果都是真实物理状态。生成结果首先受到训练数据分布和模型条件的影响，只有结合实际观测和必要的物理或任务约束进行判断，才能用于具体智能系统。因此，在存在观测缺失或状态非唯一性的情况下，生成模型更适合被理解为提供可能状态或候选恢复结果，而不是凭空确定真实世界中未被观测到的内容。

以自动驾驶系统为例，雨雾、遮挡或传感器性能下降可能导致摄像头或激光雷达只能获得部分环境信息。生成模型可以结合已有观测以及从道路场景数据中学习到的统计先验，对缺失区域形成一个或多个可能的恢复结果。例如，当目标被部分遮挡时，模型可以根据可见区域和周围场景形成关于潜在目标状态的候选估计。对于安全相关决策而言，这类结果应作为具有不确定性的辅助信息，而不能直接视为已经确认的物理事实。

因此，生成模型使信息处理从单一确定结果的恢复进一步扩展到对可能状态分布的描述。在本文所讨论的信息演化过程中，这意味着系统面对不完整观测时，不仅可以尝试恢复已有数据，还可以结合已有信息和统计先验描述可能的状态空间，从而为后续语义恢复和任务决策提供更多信息。这也为下一节讨论语义通信中受到信道扰动或信息缺失情况下的语义恢复问题奠定了基础。从信息物理学视角看，这体现了智能系统面对不完整物理观测时，从确定性恢复向概率化状态估计的发展。

4. 语义通信：智能信息传输的新范式

4.1. 从比特传输到意义传输

从信息物理学视角看，通信过程不仅是符号在物理信道中的传递，也是信息经过编码、传输和恢复后重新作用于智能系统的过程。传统通信系统建立在 Shannon 信息论基础之上，其主要目标是在有限通

信资源和信道噪声条件下实现信息的可靠传输。随着人工智能逐渐参与环境感知、信息分析和任务决策，通信系统所传递的内容不再局限于原始数据本身，还需要考虑其中哪些信息与接收端的理解和任务执行更加相关。语义通信由此将关注重点从数据层面的准确恢复进一步拓展到语义保持和任务有效性[7]。

从概念上看，传统数据传输通常关注原始数据 x 与恢复数据 $\hat{x}$ 之间的差异，其目标可以表示为：

$$\min d\left(x,\hat{x}\right) \tag{5}$$

其中，$d\left(\cdot\right)$ 表示数据层面的失真度量。语义通信并非简单降低数据误差，而是关注恢复信息是否保留了与任务相关的关键内容：

$$\min d_s\left(M\left(x\right),M\left(\hat{x}\right)\right) \tag{6}$$

其中，$M\left(\cdot\right)$ 表示由数据获得的语义表示，$d_s\left(\cdot\right)$ 表示语义层面的差异。这里的两式主要用于说明数据恢复目标与语义保持目标之间的区别。

以自动驾驶系统为例，车辆之间的信息交换并不一定需要完整传输摄像头或激光雷达采集的全部原始数据。道路中的行人位置、车辆运动状态、交通信号以及潜在障碍物等信息通常比背景纹理等低任务相关内容更直接影响驾驶决策。物理环境首先经过车载传感器形成图像、点云和雷达回波等观测数据，人工智能模型进一步从中提取“行人”“车辆”“车道线”等语义对象，通信系统则可以根据具体任务传输相关语义信息，最终由接收端用于减速、避让或路径规划等决策。由此，通信过程被连接到：物理环境→传感器观测→语义提取→信息传输→任务决策这一更完整的信息处理链条中。

深度学习的发展为语义表示与端到端通信提供了重要技术基础。Xie 等提出的 DeepSC 利用 Transformer 构建文本语义通信系统，通过联合学习语义编码、信道编码和接收端解码，在噪声信道下关注文本语义的恢复[17]。该研究表明，通信系统的优化目标可以进一步从比特或符号错误扩展到语义层面的恢复。Bourtsoulatze 等提出的深度联合信源信道编码(Deep Joint Source-Channel Coding, Deep JSCC)则利用神经网络直接学习图像源与信道符号之间的映射，实现信源表示与信道传输的联合优化[18]。需要指出的是，Deep JSCC 原始工作的主要目标仍然是图像重建质量，而不是直接优化语义或任务效用，因此它更适合作为端到端联合信息传输的重要技术基础，而不能简单等同于任务驱动的语义通信。因此，语义通信并不是对传统通信理论的否定，而是在可靠传输理论基础上进一步考虑信息所表达的意义以及其对于后续任务的作用，使通信系统的评价对象从数据恢复逐渐扩展到语义保持和任务完成效果。

4.2. 非唯一信息表示与概率化语义恢复

与上一节讨论生成模型用于一般信息恢复不同，本节进一步关注其在通信扰动条件下对任务相关语义恢复的作用。人工智能系统中的数据表示与语义内容之间往往并不存在严格的一一对应关系。这说明智能系统中的信息并不完全由物理观测本身决定，而是在物理状态、观测条件、模型表示和任务目标共同作用下形成。同一语义对象可能在不同观测条件下表现为不同的数据形式，而相同的数据表示也可能在不同任务背景下具有不同解释。

例如，对于道路中的同一车辆，不同光照条件、观察角度、距离以及天气环境可能产生不同的图像或点云数据，但这些观测仍可能对应相同的“车辆”语义对象。反过来，当观测信息受到遮挡、噪声或传输损失影响时，有限数据也可能无法唯一确定完整的原始状态。因此，面向语义和任务的信息恢复与传统数据复制存在区别，其核心问题并不是恢复唯一真实数据，而是在已有观测约束下估计满足任务需求的可能状态。

生成模型为处理这种不确定信息恢复问题提供了一种概率化方法。GAN 和扩散模型能够学习数据分布或条件数据分布[15] [16]。当传输数据受到噪声影响或部分信息缺失时，生成模型可以结合接收到的信

息以及训练数据中学习到的统计先验，对缺失内容形成一个或多个可能估计。与仅输出单一确定结果的方法相比，这种方法能够描述给定观测条件下存在的多种可能状态。

需要强调的是，生成模型输出的候选结果并不直接等同于真实物理状态。生成结果受到训练数据分布、模型结构以及输入条件的共同影响，只有结合实际观测和任务约束进行判断，才能用于智能系统。因此，在面向自动驾驶等安全关键任务时，生成式恢复更适合作为辅助信息或风险评估依据，而不能简单替代真实环境观测。

以自动驾驶场景为例，当雨雾、遮挡或传感器性能下降导致摄像头或激光雷达获取的环境信息不完整时，生成模型可以利用已有观测以及道路场景先验，对缺失区域形成多个候选估计。例如，对于被部分遮挡的目标，模型可以根据可见区域和周围环境推断潜在目标状态，而不是直接认为已经恢复了真实目标。对于后续驾驶决策而言，这类结果可以作为风险判断的辅助信息，并需要与其他传感器信息和当前车辆状态结合使用。

因此，生成式恢复使信息处理由单一确定结果的重建进一步扩展到可能状态分布的描述。在语义通信中，当信道扰动导致部分语义信息缺失时，这种概率化表示能够为接收端恢复任务相关信息提供新的途径，但其有效性仍依赖于接收信息、数据先验和具体任务之间的一致性。

4.3. 面向任务的信息交换

语义通信进一步将通信系统的关注点由数据传输拓展到任务执行。在传统通信系统中，误码率、吞吐量和传输速率等指标主要评价数据通过通信信道的可靠性和效率；而在智能系统中，通信通常只是感知–分析–决策链条中的一个环节，接收到的信息最终需要用于识别、预测、控制和决策。因此，不同信息受到相同程度的传输扰动时，对最终任务产生的影响可能完全不同。

信息的重要程度并不完全由其数据规模或统计特征决定，而取决于其与当前物理环境状态和任务目标之间的关系。例如，在自动驾驶系统中，如果信道噪声主要影响远离车辆行驶区域的背景信息，即使数据层面存在一定误差，也可能不会明显改变当前驾驶决策；但如果扰动影响前方行人的位置、运动方向或交通信号状态，则可能导致目标状态估计错误，进一步影响减速或制动决策。因此，比特错误率或数据失真并不能单独反映通信扰动对智能任务的实际影响。

面向任务的语义通信需要进一步考虑不同信息对于任务性能的贡献，并根据任务需求调整信息处理和传输策略。相关研究已经开始从语义重要性和任务需求出发设计信息压缩、传输和恢复过程。例如，任务导向语义通信方法可以根据信息对于后续任务的贡献调整信息处理方式，使有限通信资源更加集中于与当前任务相关的内容[19]。Jin 等在 2025 年的工作中提出了面向任务的自适应语义重建方案，并利用语义重要性进行压缩与恢复。

对于贯穿本文的自动驾驶案例而言，这意味着通信资源可以根据当前驾驶场景和任务需求进行差异化配置。例如，在车辆接近道路交叉口时，行人状态、前车运动信息以及交通信号状态等内容与安全决策直接相关，而部分背景视觉细节的重要程度相对较低。此时，通信系统不仅需要考虑信道条件，还需要考虑不同信息对于当前驾驶任务的贡献，使有限资源优先用于保持关键语义信息。

这一过程与控制论关注的信息反馈和状态调节具有一定联系。控制论强调系统如何通过信息反馈调整自身状态和行为[5]；而面向任务的信息通信则进一步关注哪些信息需要被获取和交换，以及这些信息如何影响后续任务执行。综合自动驾驶系统中的信息处理过程，可以表示为：物理环境→传感器观测→数据与统计特征→语义表示→通信交换→智能决策与控制。这一链条将前文讨论的信息物理实现、统计描述、人工智能表示和语义通信连接起来，也表明人工智能时代的信息传输逐渐从“是否准确复制数据”拓展到“哪些信息需要被保留，以及这些信息能否有效支持具体任务”。

5. 人工智能时代信息研究的未来发展方向

5.1. 面向智能任务的信息价值描述

随着人工智能逐渐参与感知、推理和决策过程，仅从统计不确定性描述信息已难以覆盖智能系统中信息的全部作用。对于面向智能任务的信息系统而言，信息价值不仅取决于其统计特征，还受到物理环境状态、观测条件以及任务目标的共同影响。Shannon 信息熵能够衡量随机变量的不确定程度，但并不直接描述某一信息对于具体任务的重要程度。对于智能系统而言，同样的数据在不同环境和任务条件下可能具有不同的作用，因此除了传统的信息量之外，还需要进一步关注信息对于任务完成和决策结果的贡献。

以自动驾驶系统为例，道路环境中的不同观测信息对于驾驶任务具有不同的重要程度。前方行人的位置和运动状态、前车速度以及交通信号可能直接影响车辆的减速或制动决策，而部分背景纹理即使没有被完整保留，也未必对当前驾驶任务产生同等影响。这表明，面向智能任务的信息评价还需要考虑信息与环境状态及任务目标之间的关系。

信息瓶颈理论通过压缩输入信息并保留与目标变量相关的信息，为理解信息压缩、有效表示以及任务相关性之间的关系提供了重要理论视角[20]。与此不同，算法信息论中的 Kolmogorov 复杂度通过生成一个对象所需的最短程序长度描述对象的复杂度[4]。二者分别从任务相关性和描述复杂度等角度拓展了对信息的认识，但前者主要关注表示压缩与任务目标之间的关系，后者主要关注信息描述复杂性，均难以单独刻画智能系统中信息与物理环境、语义内容和具体任务之间的动态关系。

因此，未来可以进一步探索统计信息、算法复杂度、语义相关性和任务效用之间的联系，使信息评价能够根据具体环境和任务发生变化。例如，在自动驾驶场景中，同一目标信息在正常巡航和紧急避让条件下可能具有不同的重要程度。建立能够描述这种动态任务价值的信息度量方法，将有助于进一步连接物理观测、信息表示和智能决策，并为未来智能信息系统的信息评价提供重要基础。

5.2. 人工智能与物理规律融合

人工智能模型的发展使系统能够从大量数据中学习复杂的信息表示和决策规则，但这些模型通常依赖数据分布，其性能可能受到训练数据覆盖范围和环境变化的限制。在真实物理系统中，信息产生和演化过程受到物理规律约束，因此未来智能系统需要进一步结合数据驱动方法与物理知识，以提高信息表示的可靠性、泛化能力和可解释性。

物理信息神经网络等方法[21]尝试将物理方程、边界条件或守恒关系引入人工智能模型，使模型不仅能够学习数据中的统计规律，也能够利用物理先验约束信息表示过程。然而，物理知识的引入也需要在模型复杂度、计算成本和数据利用效率之间进行权衡。过强的物理约束可能限制模型从数据中学习复杂规律的能力，而过弱的物理约束又难以保证模型在未知环境中的可靠性。因此，关键问题并非最大程度引入物理知识，而是在数据驱动能力和物理一致性之间寻找平衡。这一问题的核心并不是将人工智能模型完全转化为物理求解器，而是在保留数据驱动表达能力的同时，引入足够的物理约束提高模型可靠性。未来需要进一步探索数据驱动方法与物理规律之间的协同关系，使人工智能系统能够在复杂物理环境中实现更加可靠的信息获取、表示和利用。

5.3. 从语义通信到智能信息系统

语义通信的发展表明，未来通信系统所关注的问题可能不再局限于设备之间的数据传输，而会进一步延伸到信息如何与感知、计算和任务决策相结合。传统通信主要解决数据如何在不同节点之间可靠传

递，而面向智能任务的信息系统还需要进一步考虑哪些信息需要被采集、如何进行表示、哪些内容需要优先传输，以及接收到的信息如何用于后续判断和决策。

在有限通信带宽、计算能力和能量资源条件下，并非所有原始观测都需要采用相同的信息处理和传输策略。系统可以根据当前物理环境状态和任务需求，对信息进行选择、表示和传输，使资源更多地用于与任务直接相关的内容。这使信息处理逐渐从单一的数据传输过程扩展为由感知、计算、通信和决策共同组成的信息处理链。

自动驾驶系统为这种变化提供了典型案例。道路环境首先经过摄像头、激光雷达和毫米波雷达等传感器形成观测数据，人工智能模型从中提取车辆、行人、车道线和交通信号等语义信息；当车辆之间或车辆与路侧设施需要交换信息时，可以进一步根据驾驶任务和通信条件选择需要传输的内容；接收端再将这些信息与本地感知和车辆状态结合，用于路径规划、风险判断和车辆控制。由此形成物理环境→感知→信息表示→通信→决策与控制的完整信息循环。

在这一过程中，传感器性能和环境条件影响信息获取，人工智能模型影响信息表示，通信资源限制信息交换，而最终任务决定不同信息的实际作用。因此，未来智能信息系统需要更加系统地协调感知、表示、通信、计算和决策过程，使信息由对物理环境的记录进一步转化为能够有效支持智能任务的资源。这种由“传输数据”向“获取、表示和利用任务相关信息”的拓展，体现了信息物理学视角下信息角色的转变，即信息不再只是被传输的对象，而成为连接物理环境、计算过程和智能决策的重要资源。

6. 结论

信息概念的发展反映了人类认识和利用物理世界方式的变化。从物理状态描述到统计表征，再到人工智能时代面向任务的信息表示，信息研究逐渐由“描述信息”拓展到“理解信息”和“利用信息”。

本文围绕人工智能时代的信息演化及其物理基础进行了讨论。首先，从信息与物理状态之间的关系出发，介绍了信息处理的物理实现以及 Shannon 信息论对统计信息的数学描述，并进一步讨论了从统计信息到语义信息的发展。随后，分析了表征学习、大规模模型和生成模型对信息表示与恢复方式的影响，其中人工智能模型能够从观测数据中形成高层表示，而这些算法过程最终仍需要依托具体的计算、存储和数据传输过程实现。语义通信则进一步展示了信息处理目标由数据恢复向语义保持和任务有效性拓展的趋势。

贯穿全文的自动驾驶案例具体展示了这一演化过程。道路环境首先通过传感器形成图像、点云和雷达回波等观测数据，经过统计处理和人工智能模型进一步形成“行人”“车辆”“车道线”等语义表示，相关信息通过通信和计算最终用于减速、制动、避让以及路径规划等任务。因此，信息在实际智能系统中的处理可以表现为从物理状态–传感器观测–数据与统计特征–语义表示–信息交换–任务决策逐步展开的连续过程。同时，传感器观测条件、计算和通信资源以及具体任务需求都会影响这一过程以及不同信息的重要程度。

从这一发展趋势看，未来的信息研究还需要进一步建立统计信息、语义表示、物理约束和任务价值之间的联系。信息价值的描述、人工智能与物理规律的融合，以及感知、通信、计算和决策的一体化，都可能成为智能信息系统的重要研究方向。通过进一步理解信息如何从物理环境中产生、如何经过人工智能模型被表示和处理，以及如何最终支持具体任务，推动信息系统由“描述信息”和“传输信息”进一步向“理解信息”和“利用信息”发展。

参考文献

[1] Shannon, C.E. (1948) A Mathematical Theory of Communication. *Bell System Technical Journal*, **27**, 623-656. https://doi.org/10.1002/j.1538-7305.1948.tb00917.x

[2] Landauer, R. (1961) Irreversibility and Heat Generation in the Computing Process. *IBM Journal of Research and Development*, **5**, 183-191. https://doi.org/10.1147/rd.53.0183

[3] Nielsen, M.A. and Chuang, I.L. (2010) Quantum Computation and Quantum Information. Cambridge University Press.

[4] Li, M. and Vitányi, P. (2019) An Introduction to Kolmogorov Complexity and Its Applications. 4th Edition, Springer. https://doi.org/10.1007/978-3-030-11298-1

[5] Wiener, N. (1948) Cybernetics: Or Control and Communication in the Animal and the Machine. MIT Press.

[6] Garcez, A.D. and Lamb, L.C. (2023) Neurosymbolic AI: The 3rd Wave. *Artificial Intelligence Review*, **56**, 12387-12406. https://doi.org/10.1007/s10462-023-10448-w

[7] Wheeler, D. and Natarajan, B. (2023) Engineering Semantic Communication: A Survey. *IEEE Access*, **11**, 13965-13995. https://doi.org/10.1109/access.2023.3243065

[8] Jaynes, E.T. (1957) Information Theory and Statistical Mechanics. *Physical Review*, **106**, 620-630. https://doi.org/10.1103/physrev.106.620

[9] Shannon, C.E. and Weaver, W. (1949) The Mathematical Theory of Communication. University of Illinois Press.

[10] Bar-Hillel, Y. and Carnap, R. (1953) Semantic Information. *The British Journal for the Philosophy of Science*, **4**, 147-157. https://doi.org/10.1093/bjps/iv.14.147

[11] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. https://doi.org/10.1038/nature14539

[12] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł. and Polosukhin, I. (2017) Attention Is All You Need. *Advances in Neural Information Processing Systems*, **30**, 5998-6008.

[13] Devlin, J., Chang, M.W., Lee, K. and Toutanova, K. (2019) BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of the* 2019 *Conference of the North American Chapter of the Association for Computational Linguistics*: *Human Language Technologies*, *Volume* 1 (*Long and Short Papers*), Minneapolis, 2-7 June 2019, 4171-4186. https://doi.org/10.18653/v1/n19-1423

[14] Sze, V., Chen, Y.H., Yang, T. and Emer, J.S. (2017) Efficient Processing of Deep Neural Networks: A Tutorial and Survey. *Proceedings of the IEEE*, **105**, 2295-2329. https://doi.org/10.1109/jproc.2017.2761740

[15] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y. (2014) Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, **27**, 2672-2680.

[16] Ho, J., Jain, A. and Abbeel, P. (2020) Denoising Diffusion Probabilistic Models. *Advances in Neural Information Processing Systems*, **33**, 6840-6851.

[17] Xie, H., Qin, Z., Li, G.Y. and Juang, B.H. (2021) Deep Learning Enabled Semantic Communication Systems. *IEEE Transactions on Signal Processing*, **69**, 2663-2675. https://doi.org/10.1109/tsp.2021.3071210

[18] Bourtsoulatze, E., Burth Kurka, D. and Gunduz, D. (2019) Deep Joint Source-Channel Coding for Wireless Image Transmission. *IEEE Transactions on Cognitive Communications and Networking*, **5**, 567-579. https://doi.org/10.1109/tccn.2019.2919300

[19] Jin, Z., Song, T., Jia, W., Zou, W. and Song, X. (2025) Task-Oriented Semantic Communication with Adaptive Semantic Reconstruction Network. *IEEE Internet of Things Journal*, **12**, 35784-35798. https://doi.org/10.1109/jiot.2025.3579582

[20] Tishby, N., Pereira, F.C. and Bialek, W. (2000) The Information Bottleneck Method. *Proceedings of the* 37*th Annual Allerton Conference on Communication, Control and Computing*, Monticello, 22-24 September 1999, 368-377.

[21] Raissi, M., Perdikaris, P. and 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