

面向复杂地下介质：人工智能缓解全波形反演难题综述

赵虹阳，袁秋霞，王承伟*

新疆理工职业大学人工智能学院，新疆 草湖

收稿日期：2026年7月26日；录用日期：2026年8月18日；发布日期：2026年9月1日

摘要

全波形反演(Full-Waveform Inversion, FWI)能够利用地震记录中的全波形信息实现高精度成像，是当今复杂地下介质速度建模与储层刻画中最受关注的地球物理技术之一，已广泛应用于油气勘探、深部地质探测、地下储碳及地震灾害评估等领域。然而FWI本质上是一个强非线性、非凸且病态的逆问题。当面对复杂地层、强非均质介质、速度剧烈变化以及观测数据稀疏含噪等情况时，周期跳跃、局部最优、收敛缓慢、成像畸变等问题往往十分突出，给实际工程应用带来了很大困难。近年来，人工智能技术凭借其在非线性拟合、特征提取、自适应优化及数据降噪等方面的能力，为改善复杂介质FWI的效果开辟了新途径。本文围绕复杂地下介质条件下传统FWI面临的主要困难，对现有的人工智能改良方法——包括物理驱动、数据驱动与混合驱动三大类——的技术原理、适用场景和各自优劣进行了分类梳理，同时归纳了当前研究的不足之处，并对未来发展方向做了展望，以期复杂地质条件下波形反演成像的进一步发展提供参考。

关键词

复杂地下介质，全波形反演，人工智能，物理约束，非线性优化，地震成像

A Review on Alleviating Full-Waveform Inversion Problems Using Artificial Intelligence for Complex Subsurface Media

Hongyang Zhao, Qiuxia Yuan, Chengwei Wang*

School of Artificial Intelligence, Xinjiang Vocational University of Technology, Caohu Xinjiang

Received: July 26, 2026; accepted: August 18, 2026; published: September 1, 2026

*通讯作者。

文章引用：赵虹阳，袁秋霞，王承伟. 面向复杂地下介质：人工智能缓解全波形反演难题综述[J]. 交叉科学快报, 2026, 10(5): 1160-1168. DOI: 10.12677/isl.2026.105136

Abstract

Full-Waveform Inversion (FWI) achieves high-precision subsurface imaging by utilizing full waveform information contained in seismic records. As one of the most popular geophysical technologies for velocity modeling and reservoir characterization of complex subsurface media, FWI has been widely applied in hydrocarbon exploration, deep geological survey, underground carbon storage, seismic hazard assessment and other fields. Nevertheless, FWI is inherently a strongly nonlinear, non-convex and ill-posed inverse problem. When dealing with complex strata, strongly heterogeneous media, drastic velocity variations, as well as sparse and noisy observed data, severe issues such as cycle skipping, local optima, slow convergence and imaging distortion frequently emerge, posing substantial obstacles to practical engineering applications. In recent years, artificial intelligence (AI) technologies, with outstanding capabilities in nonlinear fitting, feature extraction, adaptive optimization and data denoising, have opened up new avenues for improving the performance of FWI for complex media. Focusing on the core challenges encountered by conventional FWI under complex subsurface geological conditions, this paper systematically categorizes and reviews existing AI-enhanced FWI methods into three major branches: physics-driven, data-driven and hybrid-driven frameworks. It elaborates on their technical mechanisms, applicable scenarios, respective advantages and limitations, summarizes the deficiencies of current research, and prospects future development trends, aiming to provide references for the further advancement of waveform inversion imaging under complicated geological conditions.

Keywords

Complex Subsurface Media, Full-Waveform Inversion, Artificial Intelligence, Physical Constraint, Nonlinear Optimization, Seismic Imaging

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

地球物理勘探的核心任务之一,是对地下介质进行精准成像并反演其物性参数。准确刻画地层结构、速度分布与岩性特征,无论对油气资源勘探开发,还是对深部构造解析、地下空间利用和地质灾害预警,都有着重要的实际意义。在众多地震成像方法中,全波形反演(FWI)因能够利用波形、振幅、相位等全维度信息,在分辨率和精度上明显优于传统的层析成像和偏移成像,已成为高精度地震成像领域最受关注的技术路线。

然而,随着勘探目标逐渐转向深层、复杂构造区和非常规储层,实际遇到的地下介质往往具有强非均质、各向异性、断裂发育等特点,传统基于梯度迭代的 FWI 方法其局限性愈发突出。具体来说:常规 FWI 对初始模型精度要求很高,复杂介质条件下非线性畸变严重;数值正演计算量大、收敛速度慢;稀疏含噪的地震数据还会进一步放大成像误差。虽然正则化优化和多尺度迭代等传统改良手段能起到一定作用,但难以从根本上克服 FWI 在复杂介质中的固有局限性。

人工智能技术的介入为这一困境提供了新的解决思路。深度学习、自监督学习、物理约束学习、自动微分等方法能够自适应地提取数据特征、拟合非线性映射,并在物理规则约束下进行优化,从而改善复杂介质条件下 FWI 的稳定性、精度和效率。目前国内外学者已提出多种改良框架,初步形成了数据驱动、物理驱动、人机混合驱动三类技术路线。不过,这些方法各自的适用范围和瓶颈还缺乏系统的梳理

和比较。

本文即围绕这一问题展开综述：先分析复杂地下介质中传统 FWI 面临的核心困难及其成因，再分类介绍各类人工智能方法的技术原理与研究进展，最后总结现有局限并展望未来方向，希望为复杂地质条件下 FWI 技术的持续改进提供参考。

2. 复杂地下介质下传统全波形反演核心难题

FWI 的基本思路并不复杂：基于波动方程做正演模拟，最小化观测与模拟数据之间的残差，通过梯度迭代不断更新速度、密度等参数，使模型逐步逼近真实地下结构。数学上这是一个强非线性逆问题。在简单的层状均匀介质中，反演通常能稳定收敛；但遇到复杂非均质介质，多种内在挑战就会被放大。

2.1. 强非线性与周期跳跃

复杂地下介质中常见的速度突变、褶皱构造、断裂破碎带等，会使地震波传播路径变得复杂，产生明显的波形畸变和相位偏移。传统 FWI 多采用 L2 范数构建残差函数，而该函数对相位误差极为敏感——一旦初始模型与真实模型偏差超过半个波长，就容易出现周期跳跃，迭代陷入局部极值而偏离正确方向。介质的非均质性还会进一步加剧波形的非线性畸变，扩大周期跳跃的发生范围。可以说，这是传统 FWI 在复杂条件下成像失真的一个主要原因。

2.2. 初始模型依赖与病态性

FWI 的迭代求解对初始速度模型要求很高：初始模型好，收敛稳定；初始模型差，反演就容易发散、成像畸变、深层模糊。问题在于，复杂地下介质条件下，常规层析成像和偏移速度分析很难给出足够精确的初始模型。与此同时，FWI 是典型的不适定逆问题——观测数据维度有限而模型参数维度庞大，解的不唯一性很突出。微小的观测噪声和数值误差都会在迭代中被放大，反演结果的可靠性难以保证。

2.3. 计算效率与深层成像

传统 FWI 每一轮迭代都要跑一遍完整的正演、残差计算、梯度求解和模型更新流程，计算量本来就大。而在复杂介质中，为刻画地质细节不得不采用精细网格，计算成本更是成倍增加。大规模三维工区的反演耗时往往很长，难以满足实际生产中快速成像的需求。另一方面，复杂地层的深层信号衰减严重、照明不足，浅层的波形散射还会干扰深层数据，传统 FWI 很难有效区分信号与噪声，深层薄互层和隐蔽储层的成像质量因此大打折扣。

2.4. 多参数耦合

复杂地下介质中速度、密度、各向异性参数、衰减参数等多种物性参数之间存在耦合效应。而常规 FWI 大多只反演单一参数，忽略了参数间的内在联系。多参数波动方程中隐式的耦合关系会引起参数串扰——更新一个参数时其他参数也跟着跑偏，无法实现多参数的高精度同步反演，对非常规储层的精细评价形成制约。

3. 人工智能缓解 FWI 难题的核心技术体系

面对传统 FWI 在复杂介质中暴露出的种种不足，国内外研究者尝试将人工智能技术与之结合。总体来看，现有方法可以分为数据驱动、物理驱动和混合驱动三大类，各有侧重。

3.1. 数据驱动型方法

这类方法的核心思路是：用大量地震数据和地下模型样本训练神经网络，让网络自动学习波形与介

质参数之间的映射关系，从而跳过传统的迭代正演过程。其优势在于——不存在周期跳跃和局部最优的困扰，计算速度快，适合复杂介质的快速成像。

早期的做法以监督学习为主，用 CNN 或 RNN 搭建端到端模型，输入波形直接输出速度模型。但监督学习需要大量高质量标注样本，复杂介质的样本获取困难，泛化性也不理想，离实际勘探应用有不小的距离。近年来研究重心因此逐渐转向自监督学习和伪标签学习，试图利用无标注的实测数据来突破样本瓶颈。

如图 1 所示，Wu 等[1]提出的自监督多参数反演方法，利用先验层析成像和偏移成像结果构建伪标签，通过模型更新与伪标签优化的双向迭代来处理多参数耦合问题，在成像精度和参数一致性上比传统 FWI 有明显进步。如图 2 所示，Li 等[2]则提出了多尺度渐进式伪标签策略，用多尺度特征提取来削弱浅层干扰、增强深层信号，对深层照明不足和成像模糊的问题效果较好，提升了薄储层的分辨率。




Figure 1. Workflow of self-supervised multi-parameter inversion framework [1]
图 1. 自监督多参数反演框架工作流程[1]




Figure 2. Workflow of progressive pseudo-label self-supervised deep learning inversion [2]
图 2. 渐进式伪标签自监督深度学习反演工作流程[2]

不过数据驱动方法的短板也很明显：缺乏物理约束，泛化能力有限，对训练集之外的极端构造适应性差，有时会产生不符合地质规律的假象。说白了，网络“学会”的只是数据中的统计规律，而非真实的物理过程。

3.2. 物理驱动型方法

纯数据驱动方法最大的问题是脱离物理，物理驱动方法正是针对这一点做出的改进：将波动方程、地质先验等物理规则嵌入神经网络的训练过程，让网络在学习数据特征的同时也遵守物理规律。武国宁等[3]驱动全波形反演中传统优化算法易陷入局部极小、收敛慢的问题，在统一物理约束框架下对比了SGD、Adagrad、RMSProp、Adam、AdamW、NAdam、RAdam 七种自适应优化算法的反演效果。该研究验证了自适应优化策略可提升物理驱动 FWI 的求解性能，为复杂地层反演提供了优化参考。如图 3 所示，这类方法既能利用人工智能的优化能力，又能保证反演结果的物理合理性，是当前高精度反演研究的主流方向。

知识背景：优化算法是神经网络训练中用于更新模型参数、最小化损失函数的核心方法。随机梯度下降(SGD)是最基础的优化器，通过小批量样本的梯度逐步更新参数；而 Adam、RMSProp、Adagrad 等自适应优化算法则能够根据参数的历史梯度自动调整学习率，加快收敛速度并提高稳定性。在 AI 驱动的全波形反演(FWI)中，优化算法的选择直接影响网络训练的收敛速度、反演精度以及对局部极小值的规避能力，是决定物理约束网络训练效果的关键因素。




Figure 3. Physics-informed FWI neural network model [3]

图 3. 基于物理信息约束的全波形反演网络模型[3]

物理信息神经网络(Physics-Informed Neural Networks, PINN)是一类将物理定律嵌入神经网络训练过程的深度学习框架。其核心思想是将控制方程(如波动方程)的残差、边界条件和初始条件作为损失函数的软约束项，使网络在拟合观测数据的同时自动满足物理规则。在全波形反演任务中，PINN 可直接从地震数据中反演地下速度模型，无需依赖传统正演模拟器，且对噪声和稀疏数据具有更好的鲁棒性。

Zerafa 等[4]系统验证了 PINN 用于复杂介质 FWI 的效果，发现物理约束确实能抑制周期跳跃和噪声干扰，提高非均质介质的反演稳定性。盖子诚等提出的方法则引入了分数阶物理约束来优化损失函数，削弱了速度剧变地层中非线性畸变的影响，改善了收敛稳定性。Gai 等[5]提出基于物理信息分数生成建模的稳健全波形反演方法，将传统“求解单一最优解”的确定性优化问题，重构为“对后验分布进行采样”的概率推断问题，通过学习观测地震数据约束下的地下速度模型概率分布，显式表达反演过程的多解性与不确定性。

自动微分技术从另一个角度优化了算法架构。Liu 等[6]构建了基于自动微分的柔性 FWI 工作流，省去了手工推导伴随方程的麻烦，通过自动微分自适应地计算梯度，在复杂介质的多参数反演中更加灵活。

Xu 等[7]把圆柱坐标系下的弹性波动方程重构为 RNN 结构, 实现了井周复杂层状介质、弯曲界面和薄低速层的高精度反演, 能识别传统方法难以分辨的亚波长薄储层。

还有一种值得关注的思路是将注意力机制与物理约束融合。Niu 等[8]构建的轴向自注意力物理约束自编码器就是如此: 注意力机制负责聚焦复杂构造和薄互层的波形特征, 物理约束负责压制噪声, 两者配合在非均质介质降噪反演中取得了不错的效果。

3.3. 混合驱动型方法

数据驱动快但缺物理, 物理驱动准但慢——混合驱动方法试图取两者之长。典型的流程是先用深度学习完成数据降噪、特征增强和初始模型优化, 再交给物理 FWI 做精细反演, 兼顾效率和精度。Li 等[9]提出的预训练 - 微调双阶段范式比较有代表性: 先在大量合成数据上预训练网络学习通用规律, 再用实测数据微调, 同时用波动方程约束来优化模型。这种方法在断裂、褶皱等复杂工区的表现明显好于传统 FWI 和单一的智能方法。

较新的连续表征全波形反演[10]通过 AI 实现介质参数的连续表征, 再结合物理约束优化, 避免了离散网格建模的精度损失, 在非均质和各向异性介质成像中连续性和细节保真度都更好。多尺度混合驱动策略则是先用深度学习补全低频信息、校正波形畸变, 再通过多尺度 FWI 从低频到高频逐步更新模型, 能较好地克服周期跳跃问题。赵虹阳[11]提出基于生成对抗网络的可学习初始速度全波形反演模型 FWI_IVLNN: 该模型以神经网络学习初始速度参数, 融合随机速度生成速度模型, 依托物理生成器生成模拟地震记录, 通过判别器区分模拟记录与观测记录, 以无监督模式同步学习初始速度模型与网络参数; 网络梯度同时回传至神经网络与物理生成器, 通过梯度更新实现数据驱动与模型驱动的协同反演。定量与定性实验验证, FWI_IVLNN 有效降低了反演对初始速度模型的依赖, 速度模型反演精度更优。

从实际应用的角度看, 混合驱动方法目前是三者中最有工程化前景的路线, 但距离真正成熟还有不短的路要走。

为更清晰地呈现三类方法的核心差异与适用场景, 表 1 从初始模型依赖、计算成本、噪声鲁棒性、物理一致性、先验信息需求等多个维度进行了横向对比。总体而言, 数据驱动方法以效率见长但物理保证不足, 物理驱动方法以可靠性取胜但计算代价高昂, 而混合驱动方法试图在二者之间寻求平衡, 是当前最具发展潜力的技术路线。

Table 1. Comparison of characteristics among data-driven, physics-driven and hybrid-driven FWI methods
表 1. 数据驱动、物理驱动与混合驱动 FWI 方法特征对比

对比维度	数据驱动方法	物理驱动方法	混合驱动方法
对初始模型的 依赖度	低 直接从数据映射模型	高 严重依赖初始模型精度	中等 物理约束提供正则化
计算成本	训练高, 推理极低	迭代成本高, 无推理阶段	训练中等, 推理低
对噪声的 鲁棒性	中等 依赖训练数据覆盖度	低 对噪声高度敏感	较强 物理约束天然正则化
物理一致性 保证	弱 无严格物理约束	强 严格满足波动方程	中等 软约束, 可调整
所需先验信息	大量标注数据需大量 “地震数据 - 速度模型” 配对样本	无需标注的速度模型样本	数据 + 物理信息的组合需部分数 据样本(可少量) + 波动方程等物理 知识
代表性工作	文献[1] [2]	文献[3]-[8]	文献[9]-[11]

续表

核心优势	推理速度极快；无需正演模拟；擅长提取数据中的非线性模式	物理可解释性强；结果可靠；泛化到未知地质场景能力强	兼顾效率与物理合理性；对数据量和初始模型要求适中；是当前最具工程应用潜力的方向
核心局限	泛化能力弱；物理可解释性差；易产生“伪影”	计算成本高；对初始模型敏感；易陷入局部极小	物理约束强度难以平衡；训练难度大；仍存在物理一致性的软约束问题

4. 现有技术局限性与研究痛点

4.1. 数据驱动方法的泛化问题

纯数据驱动方法的性能高度依赖训练集的多样性和质量。一旦遇到训练时没见过的极端构造或特殊岩性，映射关系就可能失效。更根本的问题在于，这类方法学到的只是数据中的统计规律，反演结果可能违背地震波传播的物理规律，地质解释性差，很难直接用于高精度勘探。

4.2. 物理驱动方法的计算瓶颈

物理约束神经网络训练时需要同时计算数据残差和物理方程残差，迭代次数和计算量都不小。与纯数据驱动方法比，效率优势不明显；与传统 FWI 比，改善也有限。对于超大规模三维工区，算力成本仍然是一个现实障碍。

4.3. 多参数反演尚不成熟

目前多数 AI-FWI 方法还停留在速度单参数反演阶段，涉及速度、密度、各向异性、衰减等多参数联合反演的研究很少。不同参数的非线性响应差异大，单一网络很难做到精准解耦，参数串扰问题还没真正解决，制约了复杂储层的物性精细评价。

4.4. 不确定性分析几乎空白

现有研究大多聚焦于提高成像精度，很少关注反演结果的不确定性。但实际上，数据噪声、模型误差、网络参数随机性都会导致结果波动。缺少一套成熟的不确定性量化和误差评估体系，反演结果的可靠性就缺乏说服力。

5. 发展趋势与展望

5.1. 算法的轻量化与高效化

如何在保证成像精度的前提下降低计算成本，是推动 AI-FWI 走向工程应用的关键。后续可重点围绕三方面展开研究：一是研究适用于 FWI 物理约束网络的结构化剪枝与量化方法，在不损失关键波场特征的前提下将网络参数量降低一个数量级；二是探索将波动方程解析求解器与轻量化神经算子相结合的混合正演范式，突破三维大尺度模型正演的计算瓶颈；三是设计自适应多尺度训练策略，根据地下介质复杂度动态调整网络深度与特征维度，在计算效率与成像精度之间实现最优平衡，最终实现三维复杂工区的快速高精度成像。

5.2. 多参数解耦与各向异性反演

针对多参数耦合这一老难题，可从多个层面推进解耦反演研究：首先，构建基于参数敏感度引导的多分支解耦网络，实现速度、密度与各向异性参数的分步反演与联合优化，从网络架构层面缓解参数串

扰问题；其次，研究将物理解耦约束嵌入损失函数的方法，利用物理先验缩小多参数反演的解空间、提升反演稳定性；此外，还可探索针对黏弹性介质的衰减参数反演网络架构，解决强衰减地区 Q 值估计与速度建模的耦合难题，逐步实现速度、密度、各向异性、衰减等多参数的同步反演，这对于非常规储层和深部复杂构造的精细评价尤为重要。

5.3. 向小样本乃至零样本学习迈进

深层、深海、复杂山地等工区往往面临样本稀缺的困境。可研究基于地质先验驱动的零样本 FWI 方法，通过嵌入沉积模式、构造规律等地质约束实现无标签数据下的稳定反演；探索自监督预训练与少量井数据微调相结合的小样本学习范式，在将标注样本需求降低 80% 以上的同时保持反演精度；设计自适应波形特征提取模块，通过域自适应技术实现不同工区、不同采集系统间的知识迁移，借助自监督、弱监督和零样本学习技术，通过嵌入地质先验和自适应波形特征学习来实现稳定反演。

5.4. 全流程智能化成像

长远来看，AI-FWI 不应是一个孤立的环节，而应与偏移成像、层析成像、智能降噪、数据插值等技术深度融合，形成从数据预处理到最终解释的全流程智能化体系。在技术路径上，可构建 FWI 与逆时偏移的联合反演框架，通过互馈式迭代实现速度建模与成像结果的双向优化；研究地震数据智能预处理(去噪、插值、静校正)与 FWI 的端到端一体化网络，减少人工干预环节与误差累积；同时探索基于云计算的分布式 AI-FWI 调度架构，实现多工区、多尺度任务的并行高效处理与算力资源的动态分配，结合云计算和算力加速技术，全面提升复杂地下介质的成像能力。

6. 结论

复杂地下介质的强非均质性、构造复杂性、多参数耦合以及数据稀缺含噪等特点，使传统 FWI 面临周期跳跃、局部最优、收敛缓慢、成像失真等一系列固有困难。人工智能技术从数据驱动、物理驱动和混合驱动三条路径切入，在数据优化、算法改进和物理约束等方面为这些难题提供了新的解决思路，在反演的稳定性、精度和效率上均取得了积极进展。三者之中，混合驱动方法兼顾物理合理性与数据拟合能力，是目前最接近工程应用的技术方向。

但也应该看到，当前 AI-FWI 技术仍然存在泛化性不足、算力开销大、多参数解耦能力有限、不确定性分析缺失等短板。要真正从实验室走向规模化工程应用，还需要在轻量化算法、小样本学习、多参数反演和标准化评价体系等方面持续积累。希望本文的梳理能为这一领域的后续研究提供一些参考。

基金项目

新疆理工职业大学 2025 年校长基金项目(XGZDZK202510)。

参考文献

- [1] Wu, Y.L., Wang, W.L., Wang, Y.F. and McMechan, G.A. (2025) Deep Learning-Based Self-Supervised Multi-Parameter Inversion. *Geophysical Journal International*, **243**, 1-25. <https://doi.org/10.1093/gji/ggaf332>
- [2] Li, W., Zhang, H., Huo, S. and Han, J. (2026) Progressive Pseudo-Label Self-Supervised Waveform Inversion and Imaging Based on Multiscale Strategies: A Marine Data Case Application. *Petroleum Science*, **23**, 3932-3946. <https://doi.org/10.1016/j.petsci.2026.03.011>
- [3] 武国宁, 吴春勇, 杨晓璇, 等. 深度学习优化算法在全波形反演中的性能对比[J]. 中国石油大学学报(自然科学版), 2026, 50(1): 45-54.
- [4] Zerafa, C., Galea, P. and Sebu, C. (2025) Synergizing Deep Learning and Full-Waveform Inversion: Bridging Data-Driven and Theory-Guided Approaches for Enhanced Seismic Imaging. arXiv: 2502.17585.

-
- [5] Gai, Z. and Wang, Y. (2026) sFWI: Physics-Informed Score-Based Generative Modeling for Robust Full Waveform Inversion. *Machine Learning: Science and Technology*, **7**, Article 025044. <https://doi.org/10.1088/2632-2153/ae55fb>
 - [6] Liu, F., Li, H., Zou, G. and Li, J. (2025) Automatic Differentiation-Based Full Waveform Inversion with Flexible Workflows. *Journal of Geophysical Research: Machine Learning and Computation*, **2**, e2024JH000542. <https://doi.org/10.1029/2024jh000542>
 - [7] Xu, S., Liu, Y., Li, S. and Zou, Z. (2025) Automatic Differentiation-Based Borehole Full-Waveform Inversion. *IEEE Transactions on Geoscience and Remote Sensing*, **63**, 1-19. <https://doi.org/10.1109/tgrs.2025.3611007>
 - [8] Niu, Y., Qu, Y. and Li, Z. (2026) A Physics-Constrained Autoencoder for Full-Waveform Inversion Using Axial Self-Attention. *Journal of Seismic Exploration*, **35**, 1-13.
 - [9] Li, G., Li, Y., Huang, J. and Wu, X. (2025) A Pre-Training and Fine-Tuning Paradigm for Building a Subsurface Model. *Journal of Geophysics and Engineering*, **22**, 877-888. <https://doi.org/10.1093/jge/gxaf044>
 - [10] Chen, R., Luo, Y., Wu, B., *et al.* (2026) Unveiling the Mechanism of Continuous Representation Full-Waveform Inversion: A Wave Based Neural Tangent Kernel Framework. arXiv: 2603.22362.
 - [11] 赵虹阳, 王承伟, 柴变芳, 等. 可学习初始速度的全波形反演模型[J]. 西北地质, 2026, 59(4): 179-189.