

基于用户特定空间的对抗推荐模型

于晓明¹, 周 淦¹, 刘志春²

(1. 华北计算机系统工程研究所, 北京 100083; 2. 63850 部队, 吉林 白城 137000)

摘 要: 自编码器和生成对抗网络作为强大的模型已经被应用到推荐系统领域, 能补充用户项目之间的交互信息。但这种模式的训练下, 大量的辅助信息被浪费, 比如用户特定信息。结合自编码器、生成对抗网络和辅助信息, 提出了基于用户特定空间的对抗推荐模型。为建立辅助信息和交互信息的联系, 将自编码器的隐空间替换为用户特定空间, 交互信息和用户特定信息的点对点映射又限制了模型的表达, 因此, 在用户特定空间加入对抗训练增加模型的性能。在两个公开电影数据集的充分实验证明了提出模型的有效性和优越性。

关键词: 生成对抗网络; 用户特定空间; 自编码器; 推荐系统

中图分类号: TP391

文献标识码: A

DOI: 10.19358/j.issn.2097-1788.2023.03.012

引用格式: 于晓明, 周淦, 刘志春. 基于用户特定空间的对抗推荐模型 [J]. 网络安全与数据治理, 2023, 42(3): 74-79.

Adversarial recommendation model based on user-specific space

Yu Xiaoming¹, Zhou Gan¹, Liu Zhichun²

(1. National Computer System Engineering Research Institute of China, Beijing 100083, China;

2. 63850 Troop, Baicheng 137000, China)

Abstract: Auto-encoder and generative adversarial networks, as powerful models, have been applied to the field of recommendation systems to supplement the interactive information between users and items. However, under this mode of training, a large amount of auxiliary information is wasted, such as user-specific information. This paper combines auto-encoder, generative adversarial networks, and auxiliary information to propose an adversarial recommendation model based on user-specific space (USS-GAN). In order to establish the connection between auxiliary information and interactive information, the hidden space of the auto-encoder is replaced by the user-specific space. The point-to-point mapping of interactive information and user-specific information limits the representation of the model. Therefore, the adversarial training is added to the user-specific space to improve the performance of the model. Extensive experiments on two public movie datasets demonstrate the effectiveness and superiority of the proposed model.

Key words: generative adversarial networks; user-specific space; auto-encoder; recommendation systems

0 引言

信息技术的高速发展带来了互联网的信息爆炸, 许多资源得不到有效的利用, 人们在短时间内提取有效信息十分困难。推荐技术的出现帮助人们解决信息过载现象, 推荐系统就是关注历史信息中用户感兴趣的方面, 在未来推荐给用户相关的项目。最初, 机器学习在推荐系统的应用基本满足了人们的需求^[1-2], 随着深度学习的引入^[3-4], 推荐系统的性能得到了进一步的提升。

AutoRec^[3]将自编码器与协同过滤结合, 补充用户项目交互信息的缺失值, 解决数据稀疏的问题。但自编码

器的隐空间维度是由超参数控制的, 这就导致研究者不能明确网络从数据中学到的信息, 因此推荐性能不高。生成对抗网络 (Generative Adversarial Networks, GAN)^[5]作为深度学习的一种方法, 由生成器和判别器组成, 两者的对抗训练帮助生成器生成有用的数据。GAN 被广泛应用在图像^[6-7]、文本^[8]、语音^[9]各个领域。研究者也将 GAN 应用在推荐系统中, CFGAN^[10]将协同过滤与 GAN 结合, 从对抗训练中补充用户项目交互信息的缺失值, 这种方式带来了性能的极大提升, 但模型也仅依靠用户项目之间的交互信息完成推荐任务, 用户信息和项

目信息均没有得到有效利用。

本文提出了基于用户特定空间的对抗推荐模型 (Adversarial Recommendation Model Based on User-Specific Space, USS-GAN) 来解决上述的两个问题。USS-GAN 将自编码器的隐空间替换为表示用户信息为用户特定空间, 实现交互信息到用户特定空间之间的映射, 这显示地建立了交互信息和用户信息之间的关系。但这种映射造成数据的表达受限, 引入一个条件判别器, 以交互信息作为条件, 真实的用户信息和生成的用户信息作为输入, 判别两者的真实性, 指导生成器的训练, 进一步建立交互信息和用户信息之间的联系, 来缓解成对数据映射造成的影响。USS-GAN 模型有以下贡献:

- (1) 将自编码器的隐空间替换为显示表达的用户特定空间, 充分利用了数据集中的用户信息。
- (2) 用户特定空间的对抗训练增加了模型的表达能力, 缓解了交互信息与用户信息单一映射带来的影响。
- (3) 比较实验证明了提出模型的推荐效果, 消融实验证明了不同提出模块的有效性。

1 相关工作

(1) 生成对抗网络

GAN^[5] 被提出之后, 无监督领域发生了很大的变化, 仅通过生成器和判别器的对抗训练就能生成令用户满意的效果。而后, 一些改进的模型被提出来增加 GAN 的性能, 比如损失函数的改进^[11] 和训练条件的改进^[12]。目前, GAN 已经被应用到图像生成^[6-7]、自然语言处理^[8]、语音^[9] 等多个领域。多种场景的应用证明了 GAN 的强大性能, 尽管在推荐系统中也能见到 GAN 的身影^[10], 但推荐性能仍不能满足需求。

(2) 推荐系统

推荐系统是根据用户的兴趣特点或购买行为, 向用

户推荐感兴趣的信息或商品, 主要分成了 top-k 的推荐和评分的预测, 一般使用 top-k 的推荐作为推荐系统的研究方式。最初研究者从数学统计考虑, 使用机器学习模型^[1-2,13] 实现推荐功能, 而后资源的过度膨胀和深度学习的发展使得深度推荐模型被广泛研究^[3-4]。在深度学习模型中, 一个重要的分支是生成模型, IRGAN^[14] 将强化学习的策略结合到 GAN 中用于推荐。GraphGAN^[15] 提出了 graph softmax 使得 softmax 更加适应图结构。CFGAN^[10] 结合了协同过滤和 GAN, 同时提出三种负采样技术完善提出的模型。其中 IRGAN 和 GraphGAN 均使用了预训练的生成器, 本文的对抗推荐模型与 CFGAN 类似, 没有采用任何的预训练方式, 与以上模型的一个巨大的不同点是 USS-GAN 是在隐空间实现对抗训练。

2 方法

推荐系统领域通常面临稀疏的用户项目交互数据, 交互信息的增加是推荐系统研究者所期待的。自编码器作为一个良好的缺失数据的补充工具在早期就应用在推荐系统中^[3]。自编码器是将数据从原始空间编码到低维的隐空间, 再从隐空间解码到原始的数据空间, 隐空间的维度往往作为一个超参数被用于模型调节。与以上不同的是, 本文将这个不确定的隐空间更改为用户的特定空间建立输入与输出之间的联系, 另外, 交互数据与用户特定空间一对一的训练又限制了数据的表现, 因此, 在用户特定空间加入对抗训练增加模型对数据的表达。本节首先介绍模型的结构, 接下来, 引入模型训练的损失函数和训练方式。

2.1 模型概述

图 1 是模型的基本结构, 包括编码器 Enc、解码器 Dec 和判别器 D。假定有一个用户列表 $\{u_1, u_2, \dots, u_n\}$ 和一个项目列表 $\{i_1, i_2, \dots, i_m\}$, 两者之间的交互




图 1 USS-GAN 的基本结构

矩阵为 $\mathbf{UI} \in R^{n \times m}$ 。通常的自编码器将数据编码到隐空间, 隐空间的未知性增大了模型的训练代价, USS-GAN 建立交互信息与用户之间的联系, 将交互数据 $\mathbf{UI}$ 编码到已知的用户特定空间, 降低了未知性对模型训练带来的影响:

$$\bar{U} = \text{Enc}(\mathbf{UI}) \quad (1)$$

而后, 解码器将用户编码 $\bar{U}$ 解码到原始数据空间, 生成的交互信息 $\bar{\mathbf{UI}}$ 和原始交互信息之间的重构完成了自编码器的训练:

$$\bar{\mathbf{UI}} = \text{Dec}(\bar{U}) \quad (2)$$

真实用户信息和交互信息是成对用于编码器训练的, 此时一对一的持续映射将模型限制在了一定范围内, 导致模型没有充分利用数据。USS-GAN 在用户特定空间使用 GAN 训练, 用户特定空间的真实数据和编码器生成的数据连同交互信息输入到判别器判别, 这样进一步增加了交互信息与用户信息的联系, 指导编码器生成更加表达交互信息的用户特征。

2.2 损失函数

模型通过对抗损失和重构损失进行优化。

(1) 对抗损失

模型的中间域是用户特定空间, 在此空间应用对抗训练, 使用条件判别器从三个方面增强判别器的能力, 如 (3) 所示, 当真实用户信息和积极交互信息作为输入, 判别为真; 当生成的用户信息和积极交互信息作为输入, 判别为假; 当真实用户信息和消极交互信息作为输入, 判别为假。生成器训练时, 生成的用户信息和积极交互信息输入判别器, 判别为真, 指导生成器训练。

$$L_{\text{adv}}^D = \begin{cases} \text{Bce}(D(U, \mathbf{UI}), 1) \\ \text{Bce}(D(\bar{U}, \mathbf{UI}), 0) \\ \text{Bce}(D(U, \mathbf{UI}'), 0) \end{cases} \quad (3)$$

$$L_{\text{adv}}^G = \text{Bce}(D(\bar{U}, \mathbf{UI}), 1)$$

式中, L_{adv}^G 和 L_{adv}^D 分别表示生成器和判别器的损失函数, Bce 表示二元交叉熵损失, $\mathbf{UI}'$ 表示消极交互信息。

(2) 重构损失

重构损失包括两个部分, 一个是在用户特定空间中用户信息重构, 另一个是自编码器生成的交互信息重构 (式 4)。两个重构损失均使用均方误差损失计算。

$$\begin{cases} L_{\text{重构1}} = \|U - \bar{U}\|_2 \\ L_{\text{重构2}} = \|\mathbf{UI} - \bar{\mathbf{UI}}\|_2 \end{cases} \quad (4)$$

(3) 总损失

通过对抗损失和重构损失, 可以得到生成部分 L_G 和判别部分 L_D 的损失函数为:

$$\begin{cases} L_G = L_{\text{adv}}^G + L_{\text{重构1}} + L_{\text{重构2}} \\ L_D = L_{\text{adv}}^D \end{cases} \quad (5)$$

2.3 训练策略

模型由多层线性层组成, 生成器的输入层加入 Dropout 函数以 0.5 的概率随机丢弃一部分数据增加模型的性能, 除最后一层激活函数是 Sigmoid 外均使用 tanh 激活函数激活。优化器是 Adam, 参数设置为 (0.9, 0.999), 模型的初始化使用 Xavier 方法^[16]。超参数从验证集中调节确定, 学习率的范围为 {0.001, 0.005, 0.000 1, 0.000 01, 0.000 001}, batchsize 的范围为 {32, 64, 128, 256, 512}。模型训练及测试在 NVIDIA RTX 3080 GPU 中进行。

3 实验

本节是模型的实验部分, 首先介绍实验的数据集、比较基线和评价指标, 而后包括与基线比较的实验结果, 最后不同模块的消融实验。

3.1 数据集

选择公开推荐数据集 MovieLens-100K^[17] 和 MovieLens-1M^[17] 作为实验评估数据集。数据集的具体信息如表 1 所示, 数据集中包括用户对电影的 1~5 的评分, 为得到用户项目交互矩阵, 当用户对电影评分大于 3 时就认为两者产生交互, 这部分数据作为积极交互信息, 其余数据均认为两者没有发生交互^[2,4], 用户对电影评分小于 3 的数据作为消极交互数据用于判别器的训练。电影拥有不同的类型, 统计用户观看电影的类型, 最后归一化防止不同量级产生的影响, 这部分数据是用户特定空间的真实用户信息, 两个数据集的用户特定空间的维度分别是 19 和 18。在所有数据集中划分 80% 的数据用于模型的训练, 20% 的数据用于模型的测试, 训练集额外划分 20% 的数据作为验证集来调节超参数。

表 1 数据集简介

数据集	用户	项目	交互量
MovieLens-100K	943	1 682	100 000
MovieLens-1M	6 040	3 883	1 000 209

3.2 基线

基线使用 ItemKNN^[1]、BPR^[2]、FISM^[13]、P3a^[18]、CDAE^[4]、RP3b^[19]、IRGAN^[14]、CFGAN^[10] 来评估模型的性能。ItemKNN^[1] 根据用户项目矩阵计算项目-项目相似度来补充缺失值。BPR^[2] 是一种用于项目排序的通用优化方式, 来排序对用户推荐项目的相对顺序。FISM^[13] 通过学习两个低维潜在因子矩阵乘积的项目-项目相似度矩阵完成对用户的推荐。P3a^[18] 使用二分图建模用户项目的关

系, 基于图中随机游走的各种参数表示用户和项目的关系, 凭借随机游走计算项目相似度对用户推荐。CDAE^[4]使用去噪自动编码器结构, 同时集成了特定于用户的潜在特征。RP3b^[19]作为二分图顶点排序模型, 基于三跳随机游走转移概率重新排序项目。IRGAN^[14]解决了 GAN 在离散领域的问题, 结合 GAN 和强化学习应用到信息检索领域, 后拓展到推荐模型中。CFGAN^[10]是以向量为基础的对抗训练模型, 结合了 GAN 和协同过滤。

3.3 评价指标

为了评估推荐系统的性能, 使用准确率 (Precision, $P@n$)、归一化折损累计增益 (Normalized Discounted Cumulative Gain, $N@n$)、平均倒数排名 (Mean Reciprocal Rank, $M@n$) 来评估推荐模型。准确率用于评估推荐列表中正确的项目数, 归一化折损累计增益和平均倒数排名用于评估推荐列表中正确项目的排名位置。这些都是广泛使用的评价指标, 其中 n 分别为 5 和 20。

3.4 比较试验

比较结果展示在表 2 和表 3, 在 Movielens-100K 数据集中, 最优的基于 GAN 的推荐模型和其他方法的最优模型分别是 CFGAN 和 FISM。相对 CFGAN, USS-GAN 在 $P@5$ 、 $P@20$ 、 $N@5$ 、 $N@20$ 、 $M@5$ 、 $M@20$ 上分别超出 6.17%、4.87%、7.21%、5.56%、8.92%、8.22%; 相对 FISM, USS-GAN 在 $P@5$ 、 $P@20$ 、 $N@5$ 、 $N@20$ 、 $M@5$ 、 $M@20$ 上分别超出 7.55%、2.19%、7.47%、3.10%、5.55%、4.94%。在 Movielens-1M 数据集中, 最优的基于 GAN 的推荐模型和其他方法的最优模型分别是 CFGAN 和 CDAE。相对 CFGAN, USS-GAN 在 $P@5$ 、 $P@20$ 、 $N@5$ 、 $N@20$ 、 $M@5$ 、 $M@20$ 上分别超出 2.81%、1.06%、3.23%、2.11%、2.65%、2.35%; 相对 CDAE, USS-GAN 在 $P@5$ 、 $P@20$ 、 $N@5$ 、 $N@20$ 、 $M@5$ 、 $M@20$ 上分别超出 7.72%、2.15%、8.11%、2.11%、5.88%、5.03%。

表 2 Movielens-100K 的实验结果

模型	$P@5$	$P@20$	$N@5$	$N@20$	$M@5$	$M@20$
ItemKNN	0.368	0.249	0.396	0.356	0.588	0.602
BPR	0.364	0.263	0.387	0.369	0.564	0.580
FISM	0.384	0.274	0.415	0.387	0.613	0.627
P3a	0.333	0.233	0.368	0.338	0.569	0.588
CDAE	0.382	0.273	0.405	0.380	0.586	0.601
RP3b	0.364	0.249	0.397	0.365	0.594	0.612
IRGAN	0.354	0.262	0.374	0.357	0.554	0.570
CFGAN	0.389	0.267	0.416	0.378	0.594	0.608
AE	0.385	0.266	0.414	0.378	0.607	0.622
User-AE	0.398	0.275	0.431	0.393	0.631	0.644
USS-GAN	0.413	0.280	0.446	0.399	0.647	0.658

表 3 Movielens-1M 的实验结果

模型	$P@5$	$P@20$	$N@5$	$N@20$	$M@5$	$M@20$
ItemKNN	0.266	0.179	0.289	0.271	0.467	0.488
BPR	0.230	0.153	0.251	0.226	0.417	0.438
FISM	0.261	0.183	0.282	0.276	0.460	0.481
P3a	0.197	0.128	0.216	0.195	0.376	0.400
CDAE	0.272	0.186	0.296	0.285	0.476	0.497
RP3b	0.216	0.137	0.242	0.215	0.415	0.439
IRGAN	0.150	0.110	0.160	0.156	0.282	0.310
CFGAN	0.285	0.188	0.310	0.285	0.491	0.510
AE	0.277	0.180	0.302	0.277	0.481	0.501
User-AE	0.292	0.189	0.316	0.288	0.494	0.513
USS-GAN	0.293	0.190	0.320	0.291	0.504	0.522

通过数值比较可以看到, USS-GAN 模型在两个数据集的全部评价指标均达到最优, 拥有优良的推荐性能。FISM、CDAE 和 CFGAN 表现出相对有竞争力的结果, FISM 将项目-项目相似度矩阵转换成两个低维潜在因子矩阵有效地缓解了数据集稀疏的问题, 展现了较高的推荐效果。CDAE 同样使用去噪自动编码器得到了不错的推荐性能, 但模型十分依赖于隐空间维度的调节, 消耗大量的训练时间。CFGAN 通过 GAN 补充用户项目交互矩阵, 对抗和负采样的作用使得模型效果突出。ItemKNN 和 BPR 是推荐系统早期的技术, 应用机器学习方法完成推荐, 推荐效果适中。P3a 和 RP3b 基于二分图建模用户和项目的关系, 拥有较少的计算花费, 但展现的推荐效果并不佳。IRGAN 严重依赖于预训练和超参数的调节, 尽管花费一定的训练周期调节参数, 但模型仍在两个数据集中展现出较大的差异。

3.5 消融实验

模型由多个模块组成, 本节消融不同的模块来验证不同模块对实验结果的影响。(1) 对抗训练的作用, 此时模型退化成基于用户特定空间的自编码器 (Auto-Encoder based on User-specific space, User-AE)。USS-GAN 在用户特定空间应用对抗训练增强模型的性能, 在消融模型中, 去除生成对抗网络, 仅通过两个重构损失优化。(2) 用户特定空间的作用, 此时模型退化成自编码器 (Auto-Encoder, AE)。本文的核心点是用户特定空间取代了自编码器的隐空间, 消融模型使用原始隐空间, 去除了用户特定空间, 通过交互信息重构损失优化。从表 2 和表 3 展示的结果可以看到, 当消融生成对抗网络后, 整体的评价指标均有所降低, 当进一步消融用户特定空间后, 所有的评价指标达到最低。这说明将自编码器的隐空间替换为用户特定空间是有效的, 但此时交互信息到用户信息是一对一映射的, 对抗训练缓解了单一映射的模式, 进一步增加了模型的推荐性能。

4 结论

本文提出了一个新的基于 GAN 的推荐系统模型, 模型以自编码器为基础, 将隐空间替换成代表用户信息用户特定空间, 而后为了缓解交互信息与用户特定信息一对一的限制, 在用户特定空间加入对抗训练增加模型的推荐性能。整个实验在两个有名的电影数据集中进行, 充分的比较实验和消融实验都表明了提出的模型能提高推荐效果。在未来, 期望从数据增强方面进一步提升和在实际场景中应用模型。

参考文献

[1] DESHPANDE M, KARYPIS G. Item-based top-N recommendation algorithms [J]. ACM Transactions on Information Systems

(TOIS), 2004, 22(1): 143 – 177.

- [2] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback [J]. arXiv preprint arXiv: 1205.2618, 2012.
- [3] SEDHAIN S, MENON A K, SANNER S, et al. Autorec: Autoencoders meet collaborative filtering [C] // Proceedings of the 24th International Conference on World Wide Web, 2015: 111 – 112.
- [4] WU Y, DUBOIS C, ZHENG A X, et al. Collaborative denoising auto-encoders for top-n recommender systems [C] // Proceedings of the Ninth ACM International Conference on Web Search and Data Mining, 2016: 153 – 162.
- [5] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. arXiv preprint arXiv: 1406.2661, 2014.
- [6] WANG T C, LIU M Y, ZHU J Y. pix2pixHD: high resolution image synthesis and semantic manipulation with conditional GANs [C] // Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition, 2018.
- [7] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2223 – 2232.
- [8] LI J, MONROE W, SHI T, et al. Adversarial learning for neural dialogue generation [J]. arXiv preprint arXiv: 1701.06547, 2017.
- [9] GUO H, SOONG F K, HE L, et al. A new GAN-based end-to-end tts training algorithm [J]. arXiv preprint arXiv: 1904.04775, 2019.
- [10] CHAE D K, KANG J S, KIM S W, et al. CFGAN: a generic collaborative filtering framework based on generative adversarial networks [C] // Proceedings of the 27th ACM International Conference on Information and Knowledge Management, 2018: 137 – 146.
- [11] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN [J]. arXiv preprint arXiv: 1701.07875, 2017.
- [12] MIRZA M, OSINDERO S. Conditional generative adversarial nets [J]. arXiv preprint arXiv: 1411.1784, 2014.
- [13] KABBUR S, NING X, KARYPIS G. Fism: factored item similarity models for top-n recommender systems [C] // Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2013: 659 – 667.
- [14] WANG J, YU L, ZHANG W, et al. IRGAN: a minimax game for unifying generative and discriminative information retrieval models [C] // Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2017: 515 – 524.
- [15] WANG H, WANG J, WANG J, et al. Graphgan: graph representation learning with generative adversarial nets [C] // Pro-

- ceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1).
- [16] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C] //Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. JMLR Workshop and Conference Proceedings, 2010: 249 – 256.
- [17] Harper F M, KONSTAN J A. The movielens datasets: history and context [J]. ACM Transactions on Interactive Intelligent Systems (TiiS), 2015, 5(4): 1 – 19.
- [18] COOPER C, LEE S H, RADZIK T, et al. Random walks in recommender systems: exact computation and simulations [C] // Proceedings of the 23rd International Conference on World Wide Web, 2014: 811 – 816.
- [19] PAUDEL B, CHRISTOFFEL F, NEWELL C, et al. Updatable, accurate, diverse, and scalable recommendations for interactive applications [J]. ACM Transactions on Interactive Intelligent Systems (TiiS), 2016, 7(1): 1 – 34.
- (收稿日期: 2023 – 02 – 12)

作者简介:

于晓明 (1998 –), 通信作者, 男, 硕士研究生, 主要研究方向: 生成对抗网络、图像生成、推荐系统。E – mail: xyuforart@gmail.com。

周淦 (1988 –), 男, 博士, 高级工程师, 主要研究方向: 航天测控。

刘志春 (1970 –), 男, 硕士, 高级工程师, 主要研究方向: 装备系统与应用工程。

(上接第 73 页)

- [12] TAI L, LIU M. Mobile robots exploration through CNN-based reinforcement learning [J]. Robotics and Biomimetics, 2016, 3: 1 – 8.
- [13] KATO Y, KAMIYAMA K, MORIOKA K. Autonomous robot navigation system with learning based on deep Q-network and topological maps [C] //International Symposium on System Integration, 2017: 1040 – 1046.

(收稿日期: 2023 – 02 – 15)

作者简介:

李恒 (1999 –), 通信作者, 男, 硕士研究生, 主要研究方向: 移动机器人自主导航、深度强化学习。E-mail: lihenggh@mail.ustc.edu.cn。

刘轻尘 (1989 –), 男, 副研究员, 主要研究方向: 多机器人系统、网络化系统。

马麒超 (1991 –), 男, 副研究员, 主要研究方向: 分布式协同与决策。

版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部

www.pcachina.cn