

基于 Informer 神经网络的福建省货运量预测

燕学博^{1,2}, 钟凯彬³

1. 福建理工大学管理学院, 福建 福州 350118;

2. 景区交易数据要素化文化和旅游部技术创新中心, 福建 福州 350000;

3. 福建理工大学互联网经贸学院, 福建 福州 350014

摘要:为准确预测货运量,以福建省货运量为研究对象,分别从产业结构水平、经济发展水平、物流发展水平和人文因素等4个方面选取货运量的主要影响因素,以1978—2022年福建省货运量及货运量影响因素数据构建数据集,基于 Informer 神经网络构建货运量预测模型,通过交叉验证法训练模型,同时采用长短期记忆(long short-term memory, LSTM)神经网络和 Transformer 神经网络预测福建省货运量,对比三者预测结果的准确性。结果表明:Informer 神经网络模型测试集预测结果的平均相对误差为3.75%,LSTM 和 Transformer 神经网络模型预测结果的平均相对误差略高,分别为4.45%、4.38%,Informer 神经网络模型的预测结果较准确。采用 Informer 神经网络模型预测2023年福建省的货运量为184 289.0万t,比2022年增大8.9%。福建省的货运量逐年增大,应不断完善物流配送机制,提高运输效率以满足福建省及周边地区的物流需求。

关键词:货运量;预测;Informer 神经网络;交叉验证法

中图分类号:U116;F572

文献标志码:A

文章编号:1672-0032(2025)01-0016-08

引用格式:燕学博,钟凯彬.基于 Informer 神经网络的福建省货运量预测[J].山东交通学院学报,2025,33(1):16-23.

YAN Xuebo, ZHONG Kaibin. Freight volume prediction of Fujian Province based on Informer neural network[J]. Journal of Shandong Jiaotong University, 2025, 33(1): 16-23.

0 引言

随互联网技术的发展,消费场景从线下拓展到线上,网络购物用户规模不断扩大,对物流服务质量提出更高要求。精确预测货运量对促进物流业健康发展、提高物流运输服务质量及运输效率、更好满足消费者需求具有重要意义^[1]。

在提高货运量预测准确度方面,钟蒙等^[2]以第一、二产业增加值和人均国内生产总值为自变量,采用灰色-反向神经网络预测江西省公路货运量;龙宇等^[3]以2007—2021年的全国铁路货运量月度数据集为参考,构建加权组合模型预测2021年铁路货运量,结果表明加权组合模型的预测准确度高于单一模型;杨宇鸽等^[4]基于 NeuralProphet 模型与长短期记忆(long short-term memory, LSTM)神经网络构建组合模型,预测上海港和厦门港的货物吞吐量,结果表明组合模型可有效解决数据异常波动造成的预测结果误差大、预测效果不稳定等问题;彭婷等^[5]采用机器学习的线性回归方程预测武汉天河机场的货邮吞吐量,结果表明线性回归模型比二次指数平滑模型预测准确度更高;张冠东等^[6]提出多维 LSTM 神经网络预测模型,分别预测铁路、公路、民航的货运量,预测效果优于向量自回归模型;李国祥等^[7]基于 LSTM 神经网络,提出基于深度学习的区域物流预测模型,预测性能较好;徐晓燕等^[8]采用5种不同的研究方法预测山

收稿日期:2024-03-25

基金项目:福建省数字城乡融合发展科技经济融合服务平台项目(KY320389)

第一作者简介:燕学博(1980—),男,湖北十堰人,副教授,高级工程师,管理学博士,主要研究方向为电子信息和大数据, E-mail:abc@fjut.edu.cn。

东省生鲜农产品物流需求,结果表明 LSTM 神经网络的预测准确度和稳定性较好;Laan 等^[9]研究紧急情况下如何准确预测救援物资并有效规划订单,以优化资源配置和物流效率;左敏等^[10]建立 Informer 神经网络预测模型预测河北、湖北和湖南的农产品物流需求,预测结果较准确;刘妙男等^[11]考虑天气、节假日等因素对公交客流量的影响,建立 Informer 神经网络预测模型预测公交车客流量,为城市交通规划提供依据;程元栋等^[12]构建加权马尔科夫-自回归移动平均模型预测区域物流需求,结果表明组合模型的预测准确度高于一模型;王雷等^[13]分别采用季节性指数平滑法和季节差分自回归移动平均法预测铁路客运量,后者的预测准确度更高。以上研究多通过改进预测模型提高预测准确度,研究多集中在预测港口、铁路等特定交通方式的货运量,无法准确反映省份的整体物流需求。

福建省地处我国东南沿海,是重要的物流中心和交通枢纽,在满足省际物流需求同时面临物流资源投入大、物流负担重等问题^[14]。本文分别从福建省的产业结构水平、经济发展水平、物流发展水平和人文因素等方面选取货运量的主要影响因素,构建货运量及其影响因素的数据集,建立 Informer 神经网络模型^[15-16],通过模型训练预测福建省货运量需求,为提升物流配送效率、降低成本提出相关建议。

1 研究数据

1.1 数据获取

在数据源中有多种因素直接或间接影响预测准确度,需合理选取主要影响因素,减少数据冗余度。分别从产业结构水平、经济发展水平、物流发展水平和人文因素等 4 方面选取第一产业增加值 G_1 、第二产业增加值 G_2 、第三产业增加值 G_3 、工业增加值 G_4 、人均国内生产总值 G_5 、年末常住人口 G_6 、公路运营里程 G_7 、货物发送量 G_8 、货物周转量 G_9 、铁路运营里程 G_{10} 作为货运量 X 的 10 个主要影响因素,构建预测模型分析变量。其中, $G_1 \sim G_4$ 为产业因素, G_5 为经济因素, G_6 为人文因素, $G_7 \sim G_{10}$ 为物流因素。通过文献^[17]获取 1978—2022 年福建省的货运量及货运量主要影响因素数据,如表 1 所示。

表 1 1978—2022 年福建省的货运量及货运量主要影响因素数据

年份	G_1 /亿元	G_2 /亿元	G_3 /亿元	G_4 /亿元	G_5 /元	G_6 /人	G_7 /km	G_8 /万 t	G_9 /(亿 t·km)	G_{10} /km	X /万 t
1978	23.93	28.19	14.25	23.85	273	2 446	29 109	1 261	50.40	1 009	4 871
1979	27.97	31.37	14.77	26.20	300	2 487	32 112	1 318	55.17	1 009	5 149
1980	31.95	35.68	19.43	29.55	348	2 519	32 577	1 320	56.56	1 009	7 979
1981	39.30	39.75	26.57	33.16	416	2 563	32 982	1 268	55.54	1 009	8 302
1982	44.24	42.92	30.65	35.25	455	2 620	33 827	1 305	64.71	1 006	9 077
1983	47.27	42.92	34.44	37.76	483	2 668	34 445	1 334	70.06	1 005	10 175
1984	55.72	56.39	44.95	44.47	583	2 720	35 020	1 477	79.98	1 005	11 479
1985	68.13	72.56	59.79	62.09	730	2 769	35 987	1 536	82.43	1 006	13 317
1986	72.24	82.19	68.11	67.06	796	2 820	37 175	1 486	90.37	1 028	16 931
1987	89.24	101.28	88.72	82.69	981	2 875	38 148	1 802	95.69	1 028	18 231
1988	118.16	141.82	123.23	120.45	1 321	2 929	39 124	1 810	97.98	1 028	20 131
1989	135.77	163.82	158.81	142.45	1 550	2 984	39 124	1 892	101.08	1 029	19 859
1990	147.01	174.47	200.80	150.55	1 735	3 037	41 011	1 902	104.01	1 021	20 321
1991	168.64	217.74	233.49	188.29	2 027	3 079	41 745	1 988	113.00	1 015	12 124
1992	188.70	290.56	305.42	241.78	2 533	3 116	41 882	2 064	125.91	1 015	19 836
1993	246.25	454.15	413.80	381.95	3 556	3 150	43 558	2 216	136.04	1 015	25 824

表 1(续)

年份	G_1 /亿元	G_2 /亿元	G_3 /亿元	G_4 /亿元	G_5 /元	G_6 /人	G_7 /km	G_8 /万 t	G_9 /(亿 t·km)	G_{10} /km	X /万 t
1994	351.24	718.31	574.84	618.06	5 193	3 183	44 608	2 301	140.02	1 024	28 447
1995	449.77	879.12	766.01	748.92	6 536	3 227	46 574	2 456	145.69	1 024	28 922
1996	519.84	1 022.88	941.53	875.50	7 658	3 261	47 196	2 500	141.18	1 025	30 593
1997	556.45	1 210.34	1 104.11	1 039.62	8 775	3 282	47 680	2 373	143.00	1 068	30 496
1998	586.99	1 330.18	1 242.75	1 132.79	9 603	3 299	48 021	2 325	141.94	1 381	30 010
1999	607.07	1 429.01	1 378.11	1 230.22	10 323	3 316	50 202	2 389	144.09	1 383	28 637
2000	616.37	1 622.33	1 525.83	1 422.34	11 194	3 410	53 506	2 475	152.51	1 454	29 483
2001	624.15	1 796.68	1 652.02	1 586.28	11 883	3 445	53 547	2 813	164.78	1 453	30 547
2002	659.51	2 029.19	1 778.85	1 808.95	12 910	3 476	54 155	2 856	169.96	1 454	31 837
2003	682.06	2 329.67	1 987.86	2 059.30	14 330	3 502	54 876	3 206	194.34	1 467	33 422
2004	762.85	2 738.71	2 210.52	2 422.22	16 248	3 529	56 208	3 739	219.10	1 471	37 279
2005	792.53	3 095.92	2 527.02	2 744.68	18 107	3 557	58 286	3 601	201.95	1 613	40 400
2006	828.82	3 629.68	3 010.07	3 189.45	20 915	3 585	86 560	3 646	201.70	1 616	44 304
2007	951.22	4 521.78	3 852.62	3 956.44	25 915	3 612	86 926	3 595	209.70	1 630	50 500
2008	1 096.10	5 386.98	4 448.72	4 676.93	30 153	3 649	88 607	3 681	207.80	1 618	57 254
2009	1 108.80	6 129.07	5 180.22	5 218.63	33 999	3 666	89 504	3 631	182.70	2 110	58 231
2010	1 269.87	7 705.25	6 027.39	6 532.27	40 773	3 693	91 015	3 765	184.20	2 110	66 159
2011	1 492.20	9 316.55	7 108.95	7 823.21	47 928	3 784	92 322	3 826	187.93	2 255	75 272
2012	1 628.94	10 527.00	8 034.79	8 711.23	52 959	3 841	94 661	3 868	181.10	2 743	84 417
2013	1 745.17	11 805.20	8 953.17	9 650.19	58 255	3 885	99 535	3 661	164.81	2 743	96 718
2014	1 855.85	13 165.07	9 921.15	10 682.19	63 709	3 945	101 190	3 403	149.80	2 755	111 779
2015	1 932.84	13 735.68	11 150.94	11 008.70	67 649	3 984	104 585	2 820	128.71	3 197	111 063
2016	2 145.10	14 683.72	12 780.61	11 711.98	74 024	4 016	106 757	2 918	129.45	3 197	120 379
2017	2 215.12	16 290.02	15 337.30	12 864.85	83 758	4 065	108 012	3 175	135.90	3 187	132 252
2018	2 379.02	18 847.75	17 461.00	14 781.03	94 719	4 104	108 901	3 518	147.35	3 509	136 974
2019	2 595.53	20 065.48	19 665.57	15 654.00	102 722	4 137	109 785	4 086	191.61	3 509	133 693
2020	2 730.81	20 168.43	20 709.31	15 615.48	105 106	4 161	110 118	3 750	180.90	3 774	139 927
2021	2 899.91	23 319.82	23 346.32	18 292.82	118 750	4 187	111 031	5 112	201.32	3 983	166 131
2022	3 076.20	25 078.20	24 955.45	19 628.83	126 829	4 188	112 878	4 815	206.37	4 230	169 107

1.2 数据规范化

不同影响因素数量级及单位存在较大差异,采用最小-最大规范化方法处理数据量纲。采用该方法将数据映射到统一区间内,降低特殊样本数据的不良影响。规范化后的数据

$$G' = (G - G_{\min}) / (G_{\max} - G_{\min}) ,$$

式中: G 为原始数据, $G_{\max}$ 为原始数据中的最大值, $G_{\min}$ 为原始数据中的最小值。

2 研究方法

通过回归分析法构建因变量和自变量间的关系预测货运量时,难以获取所需的标准数据,预测准确

度较低。采用长时间序列预测方法分析长时间的历史数据,获取相对客观的关联系数公式,得到现象发展规律及与其他现象间的关联。

深度学习算法是人工智能的分支,在图像处理^[18]、自然语言处理^[19]、语音识别^[20]、推荐系统^[21]等方面应用广泛。Transformer 神经网络模型具有较强的捕获长距离依赖能力,在长时间序列预测中实用性较好,但存在堆叠多层网络、内存占用过高、解码速度较慢等问题。Informer 神经网络模型在 Transformer 神经网络模型上改进 3 点:提出多头概率稀疏自注意力机制筛选查询矩阵,降低计算复杂度;提出自注意力蒸馏机制,减少维度和网络参数;提出生成式解码器,一次性获得所有预测结果,提高预测速度。

基于 Informer 神经网络构建福建省货运量预测模型,如图 1 所示。Informer 神经网络模型由编码器和解码器组成。编码器负责对输入的时间序列进行编码,提取内部依赖关系,将历史货运量 $\{X_t, X_{t+1}, \dots, X_{t+i}, \dots, X_T\}$ 与货运量影响因素规范化数据作为 Informer 神经网络模型的输入,基于 Prophet 经典传统算法标记时间序列并设为位置编码,捕捉时间序列中的局部和全局前、后时间位置关系。解码器处理编码器提取的特征,经全连接器后输出预测货运量 X_{T+1} 。





图1 基于 Informer 神经网络的福建省货运量预测模型

编码器由不同功能的堆栈组成,第1个堆栈处理全部输入序列,后续堆栈依次处理前1个堆栈输出的1/2,每个堆栈包括编码层和蒸馏层,结构如图2所示。



注:Conv1d 为一维卷积层,用于处理一维时间序列数据或其他一维结构数据,Padding=2 为在输入的前、后位置各填充 2 个值,通常为 0(即零填充)。

图2 编码器堆栈结构图

编码层由多头注意力和多头概率稀疏自注意力层两部分组成。多头注意力捕捉时间序列中不同位置间的长距离依赖性,进行初步编码和特征提取;多头概率稀疏自注意力机制模仿人类的选择性视觉注意力,筛选关联度紧密的信息,通过稀疏选择策略捕捉时间序列中的关键特征,建立预测数据间的内部关系,降低计算复杂度,提高计算效率。

蒸馏层比编码层少 1 层,蒸馏层通过降采样操作提取关键特征,减小时间序列长度,降低计算复杂度,提高模型的鲁棒性。蒸馏层操作公式为^[22]:

$$x_{j+1} = \text{MaxPool}(\text{ELU}(\text{Conv1d}([x_j]_{AB}))) ,$$

式中: x_{j+1} 、 x_j 分别为第 $j+1$ 和第 j 层的输入特征;MaxPool 为最大池化操作,用于减小输入长度;Conv1d 为一维卷积操作,用于提取时间序列的特征; $[x_j]_{AB}$ 为 x_j 在通道 AB 上的值,表示对 x_j 进行某种操作,如多

头概率稀疏自注意力机制操作;ELU 为激活函数,用于引入非线性变换,

$$\text{ELU}(x) = \begin{cases} e^x - 1, & x < 0 \\ x, & x \geq 0 \end{cases}。$$

每一层归一化操作后的输出

$$O = \text{LayerNorm}(x + \text{Sublayer}(x)) ,$$

式中:LayerNorm 为正则化操作函数; x 为当前层的输入;Sublayer 为多头概率稀疏自注意力机制处理函数。

最后,将所有堆栈的输出连接起来,得到编码器的最终隐藏表示,即图 2 中的特征图。

解码器通过注意力机制提取历史数据中的特征信息,生成预测数据,输入两部分内容:一部分为编码器的最终隐藏表示,另一部分为待预测的货运量,使用 0 占位,并引入掩盖机制,在模型预测时忽略这部分输入。其注意力机制包含 Masked 多头稀疏自注意力机制和交叉注意力机制,前者保证在解码过程中保持因果关系,在生成未来时间步的预测时,只能访问序列前的时间步;后者确保解码器参考编码器生成的特征。Masked 多头稀疏自注意力机制公式为:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}(\mathbf{Q}\mathbf{K}^T / \sqrt{d} + \mathbf{M}) \mathbf{V} ,$$

式中: $\mathbf{Q}$ 为查询矩阵; $\mathbf{K}$ 为键矩阵; $\mathbf{V}$ 为值矩阵;Softmax 为激活函数; d 为键向量的维度; $\mathbf{M}$ 为屏蔽矩阵,用于计算时屏蔽未来的时间步。

交叉注意力机制公式为:

$$\text{Cross Attention}(\mathbf{Q}, \mathbf{K}_e, \mathbf{V}_e) = \text{Softmax}(\mathbf{Q}\mathbf{K}_e^T / \sqrt{d}) \mathbf{V}_e ,$$

式中: $\mathbf{K}_e$ 为编码器输出的键矩阵, $\mathbf{V}_e$ 为编码器输出的值矩阵。

全连接器接收解码器的输出,整合不同的多头自注意力机制提取的不同特征信息,输出预测货运量。

3 预测结果分析

分别采用 Informer、LSTM 和 Transformer 神经网络模型预测福建省的货运量,对比预测结果的准确性。

3.1 试验方法

采用深度学习框架 PyTorch,基于 Windows 11 操作系统,在 Python 3.6 环境下进行货运量预测试验,使用 Numpy 1.19.4、Scikit-Learn 0.21.3、Pandas 0.25.1、Torch 1.8.0 和 Matplotlib 3.1.1 等工具。

采用交叉验证法训练模型,即在数据集中切割出小部分作为测试集,剩余的大部分作为训练集,在训练过程中,随机更换不同的小部分作为测试集,以此不断更换。不断变化训练集和测试集,充分利用数据集中所有样本进行模型训练,提高模型的泛化能力;汇总多个不同测试集的预测结果,更准确地评估模型性能,减少对单一划分结果的依赖性;交叉验证可帮助检测模型是否过拟合,过拟合现象指在测试集上表现效果不好,在训练集上表现效果好。

3.2 结果分析

Informer 神经网络模型的输入包括历史货运量、时间及货运量影响因素数据,模型的输出为待预测年份的货运量。选取 LSTM 神经网络和 Transfoemer 神经网络模型作为试验的对照组。LSTM 神经网络基于循环神经网络,解决梯度消失问题,可有效捕捉和保留长期的时间依赖关系,在预测长时序问题上有一定优势。Transformer 神经网络不使用隐藏层传递相关的信息参数,直接计算任意词间的相关性,有并行计算能力,可最大程度使用图形处理器资源。

Informer、LSTM 和 Transformer 神经网络预测模型的损失函数随迭代次数的变化如图 3 所示。由图 3 可知:Informer 神经网络模型在初始阶段损失函数较大,随不断迭代训练,损失函数减小,测试集迭代约 200 次后趋于 0;LSTM 神经网络模型的训练集和测试集迭代约 300 次后损失函数趋于 0,预测效果不如 Informer 神经网络模型;Transformer 神经网络模型的测试集迭代约 250 次后,损失函数接近 0,训练集迭代约 200 次后损失函数趋于 0,迭代至 300 次时有轻微波动,预测效果稳定性比 Informer 神经网络模型差。




图3 3种神经网络模型的损失函数随迭代次数的变化

对比 Informer、LSTM 和 Transformer 神经网络模型预测结果的绝对误差和相对误差,及经交叉验证后的平均绝对误差和平均相对误差,结果如表 2 所示。由表 2 可知:经交叉验证后,Informer、LSTM 和 Transformer 神经网络模型预测结果的误差均显著减小,预测可靠性提高;3 种预测模型中,Informer 神经网络模型测试集预测结果的平均绝对误差和平均相对误差均最小,预测准确度最高。

表2 3种神经网络预测模型预测结果对比

模型	绝对误差/万 t		相对误差/%		平均绝对误差/万 t		平均相对误差/%	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
Informer	47.76	52.24	4.63	5.06	32.43	38.72	3.14	3.75
LSTM	63.39	61.54	6.14	5.96	34.79	45.95	3.37	4.45
Transformer	46.26	53.99	4.48	5.23	31.91	45.23	3.09	4.38

采用 Informer 神经网络模型进行预测,2022 年福建省的货运量为 163 379.34 万 t, 该省实际货运量为 169 107.00 万 t, 二者相对误差为 3.39%, 误差较小。预测 2023 年福建省的货运量为 184 289.00 万 t, 货运量比 2022 年增大 8.9%, 说明福建省应改进配送机制, 优化运输路线, 加强物流信息管理, 增强供应链风险管理的能力, 不断提高配送效率, 面对不断变化的市场需求提前做好准备。

3.3 消融试验

基于 2022 年福建省货运量相关数据进行消融试验, 验证所选货运量影响因素的合理性及建模参数的科学性。货运量影响因素的消融试验结果如表 3 所示。

表3 货运量影响因素的消融试验结果

序号	G_1	G_2	G_3	G_4	G_5	G_6	G_7	G_8	G_9	G_{10}	相对误差/%
1	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	3.39
2	×	✓	✓	✓	✓	✓	✓	✓	✓	✓	3.51
3	✓	×	✓	✓	✓	✓	✓	✓	✓	✓	3.54
4	✓	✓	×	✓	✓	✓	✓	✓	✓	✓	3.77
5	✓	✓	✓	×	✓	✓	✓	✓	✓	✓	3.62
6	✓	✓	✓	✓	×	✓	✓	✓	✓	✓	3.47
7	✓	✓	✓	✓	✓	×	✓	✓	✓	✓	4.01
8	✓	✓	✓	✓	✓	✓	×	✓	✓	✓	3.54
9	✓	✓	✓	✓	✓	✓	✓	×	✓	✓	3.64
10	✓	✓	✓	✓	✓	✓	✓	✓	×	✓	3.58
11	✓	✓	✓	✓	✓	✓	✓	✓	✓	×	3.52

注:✓为考虑该影响因素,×为不考虑该影响因素。

由表 3 可知:以 9 个影响因素为自变量时的 Informer 神经网络模型预测结果的相对误差均大于以 10 个影响因素作为自变量时的预测结果的相对误差,说明所选影响因素合理,符合建模需求。

4 结束语

为预测福建省货运量,分别从产业结构水平、经济发展水平、物流发展水平和人文因素等方面选取货运量的 10 个主要影响因素,构建 Informer 神经网络模型,与 LSTM 神经网络和 Transformer 神经网络模型对比,分析 3 种模型的预测准确度。结果表明:LSTM 和 Transformer 神经网络模型的预测准确度略低,Informer 神经网络模型预测效果最好。采用 Informer 神经网络模型预测 2023 年福建省的货运量为 184 289.00 万 t,比 2022 年增大 8.9%。福建省应改进物流设施建设,提升运输能力和完善物流配套服务,以应对不断增长的市场需求。

本文选取的数据指标较多,数据的索引难度较大,效率较低。下一步可细分为航空货运、港口货运、铁路货运等不同物流领域,从经济发展水平、产业结构水平和人文因素 3 个方面,选取代表各领域发展水平的货运量评价指标,以简化数据,提高研究效率及可操作性。

参考文献:

- [1] 徐玉萍,邓俊翔,蒋泽华.基于组合预测模型的铁路货运量预测研究[J].铁道科学与工程学报,2021,18(1):243-249.
- [2] 钟蒙,薛运强,周珣,等.基于灰色-反向传播神经网络的江西省公路货运量预测[J].科学技术与工程,2021,21(24):10478-10484.
- [3] 龙宇,许浩然,余华云,等.基于 ARIMA-LSTM-XGBoost 组合模型的铁路货运量预测[J].科学技术与工程,2023,23(25):10879-10886.
- [4] 杨宇鸽,郝杨杨,王逸文.基于 NeuralProphet-LSTM 组合模型的港口货物吞吐量预测[J].中国航海,2023,46(4):85-92.
- [5] 彭婷,邓旭东.基于机器学习的天河机场物流预测研究[J].物流科技,2023,46(5):97-100.
- [6] 张冠东,杨琛.基于多维长短期记忆网络的货运量预测[J].统计与决策,2022,38(12):180-183.
- [7] 李国祥,马文斌,夏国恩.基于深度学习的物流需求预测模型研究[J].系统科学学报,2021,29(2):85-89.
- [8] 徐晓燕,杨慧敏,吕修凯,等.基于山东省不同模型的物流需求预测比较研究[J].包装工程,2022,43(23):207-215.
- [9] LAAN E V D, DALEN J V, ROHRMOSER M, et al. Demand forecasting and order planning for humanitarian logistics: an empirical assessment[J]. Journal of Operations Management, 2016, 45:114-122.
- [10] 左敏,胡天宇,董微,等.基于 Informer 神经网络的农产品物流需求预测分析:以华中地区为例[J].智慧农业(中英文),2023,5(1):34-43.
- [11] 刘妙男,王魏,胡显辉,等.基于因果卷积和 Informer 模型的城市公交客流预测[J].控制工程,2024,31(8):1445-1454.
- [12] 程元栋,喻可欣,李先洋.基于加权马尔科夫-ARIMA 修正模型的区域物流需求预测[J].山东交通学院学报,2023,31(3):22-28.
- [13] 王雷,金勇,刘岩.铁路客运量预测模型对比分析[J].山东交通学院学报,2020,28(3):25-32.
- [14] 陈怀钧.新时代福建物流业高质量发展对策研究[J].现代营销(经营版),2020(8):80-81.
- [15] 杨海民,潘志松,白玮.时间序列预测方法综述[J].计算机科学,2019,46(1):21-28.
- [16] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the AAAI conference on artificial intelligence. [S.l.]: AAAI-51, 2020.
- [17] 福建省统计局,国家统计局福建调查总队.福建统计年鉴[M].北京:中国统计出版社:1979-2023.
- [18] 刘皓皎,刘力双,张明淳.基于 YOLOv5 改进的红外目标检测算法[J].激光技术,2024,48(4):534-541.
- [19] 李建平,陈海鸥.基于改进长短期记忆网络的文本分类方法[J].重庆大学学报,2023,46(5):111-118.
- [20] 沈逸文,孙俊.结合 Transformer 的轻量化中文语音识别[J].计算机应用研究,2023,40(2):424-429.

- [21] 林幸,邵新慧. 基于图神经网络的推荐系统模型[J]. 计算机应用与软件, 2023, 40(3): 325-330.
- [22] 熊佳豪,李锋,汤宝平,等. 基于策略梯度 Informer 模型的滚动轴承剩余寿命预测[J]. 工程科学与技术, 2024, 56(4): 273-286.

Freight volume prediction of Fujian Province based on Informer neural network

YAN Xuebo^{1,2}, ZHONG Kaibin³

1. School of Management, Fujian University of Technology, Fuzhou 350118, China;

2. Technology Innovation Center of Factored Data in Smart Culture and Tourism, Ministry of Culture and Tourism, Fuzhou 350000, China;

3. School of Internet Economics and Business, Fujian University of Technology, Fuzhou 350014, China

Abstract: To accurately predict freight volume, this study examines the freight volume in Fujian Province by selecting the main influencing factors of freight volume from four aspects: industrial structure level, economic development level, logistics development level, and human factors. A dataset is constructed using data on freight volume and its influencing factors in Fujian Province from 1978 to 2022. Based on the Informer neural network, a freight volume prediction model is constructed and trained using cross-validation methods. Simultaneously, the study employs long short-term memory (LSTM) neural networks and Transformer neural networks to predict the freight volume in Fujian Province, comparing the prediction accuracies of the three models. The results show that the average percentage error of the test set for the Informer neural network model is 3.75%, which is smaller than that of the LSTM and Transformer neural network models, at 4.45% and 4.38%, respectively, which indicates that the Informer neural network model provides more accurate predictions. The Informer neural network model predicts that the freight volume in Fujian Province in 2023 will be 1 842.89 million tons, an increase of 8.9% over 2022. The freight volume in Fujian Province is increasing year by year, and there should be continuous improvements to the logistics distribution mechanism and enhancements in transportation efficiency to meet the logistics demands of Fujian Province and the surrounding regions.

Keywords: freight volume; prediction; Informer neural network; cross-validation

(责任编辑:赵玉真)