待提交

俄乌战争：对各国情感趋势进行建模与聚类

Hamed Vahdat-Nejad*Mohammad Ghasem Akbari**，Fatemeh Salmani*，Faezeh Azizi*，

Hamid-Reza Nili-Sani**

* PerLab，比尔詹德大学电气与计算机工程学院，伊朗比尔詹德**比尔詹德大学统计系，伊朗比尔詹德

电子邮箱：vahdatnejad@birjand.ac.ir，g_z_akbari@birjand.ac.ir，
salmani_fatemeh98@birjand.ac.ir，faezeh.azizi1995@birjand.ac.ir，hnilisani@birjand.ac.ir

摘要

随着 Twitter 的发展和普及，用户围绕各种主题分享了大量观点，使这一平台成为有关各种政治、社会和经济议题的宝贵信息来源。本文研究有关俄乌战争的英文推文，分析反映用户对这场冲突的看法和情感趋势。我们使用基于BERT的模型分析推文中的正面和负面情感，并计算各国正面和负面推文频率所对应的时间序列。随后，我们提出一种基于邻域平均值的方法，用于对各国的时间序列进行建模和聚类。聚类结果为了解公众对这场冲突的看法提供了宝贵参考。其中值得一提的是，美国、加拿大、英国和大多数西欧国家的用户观点相似，而东欧、斯堪的纳维亚、亚洲和南美洲国家对这场冲突也持有相近看法。

关键词 ds：社交网络挖掘、俄乌战争、情感分析、聚类 g

1. 引言

社交网络目前是人口信息提取最重要的平台之一。社交网络用户会在许多领域分享无数帖子，包括社会、经济和政治领域，这些帖子反映了他们对全球事件和事故的看法与情感（Crannell、Clark、Jones、James 和 Moore，2016）。作为一种社交网络，Twitter 是用户情感和观点的重要来源。可以利用自然语言处理和数据检索来分析用户的观点。

自然语言处理（NLP）“专注于设计和分析用于处理人类自然语言的计算算法和表征”（Eisenstein，2018年）。其目标是提供“围绕人类语言的新型计算能力”（Eisenstein，2018年）。事实上，我们可以运用自然语言处理技术从海量文本中提取信息。

情感分析是一种很有前景的自然语言处理技术，可用于从文本中提取情绪状态和主观信息（Zad、Heidari、Jones 和 Uzuner，2021年）。它能够提取用户针对各种事件和议题发布的推文中的情感。例如，COVID-19疫情是一项全球性的重要事件，许多用户都表达了对此的观点。此外，人们还对与COVID-19相关的推文（Vahdat-Nejad 等，2022年）、COVID-19疫情期间经济状况相关的推文（Salmani、Vahdat-Nejad 和 Hajiabadi，2021年），以及COVID-19流行期间教育相关的推文（Jamalian、Vahdat-Nejad 和 Hajiabadi，2022年）等进行了情感分析。战争和冲突等其他事件也促使用户发布推文并对其进行分析。例如，对有关叙利亚难民的土耳其语和英文推文进行情感分析后发现，土耳其语推文整体基调以阳性为主，而英文推文则以负面为主（Öztürk 和 Ayvaz，2018年）。

同样，对阿富汗近期事件的观点分析显示，包含恐怖分子、袭击、摧毁和暴力等负面词语的推文占据主导地位

（Aggarwal、Khan 和 Kakkar，2022年）。此外，在八个受调查国家中，负面推文与正面推文的比例完全相同，这表明这些国家对阿富汗近期事件持有相似的情感（Aggarwal 等人，2022年）。同样，对有关叙利亚化学战的推文进行情感分析显示，用户对叙利亚化学袭击持负面看法（Bashir 等人，2021年）。

俄乌战争可能是2022年最引人注目的事件。近期，研究人员提取了中国微博社交网络上关于这场冲突讨论的主要话题（Chen 等人，2022年）。据我们所知，尚无研究分析有关这场战争的推文，以考察并分类各国的态度。为此，本研究收集并分析了有关这场冲突的推文，根据各国民众态度对其进行聚类。研究使用关键词“乌克兰”，收集了战争爆发第一个月（2022年3月）发布的14万条推文。为分析推文的情感，我们采用基于语言的 RoBERTa（Liu 等人，2019年）模型，该模型相较于类似模型具有更高的准确度和性能（Briskilal 和 Subalalitha，2022年）。随后，我们计算并建模了若干拥有足够数量英文推文的国家中正面和负面情感的频率时间序列。接下来，依据邻域平均法对各国的时间序列模型进行聚类。结果表明，美国、英格兰、加拿大和西欧国家属于同一类，而东欧、斯堪的纳维亚、南美洲和亚洲国家则属于另一类。此外，乌克兰单独归为一类，表明在冲突爆发的第一个月，该国的公众舆论趋势与世界其他地区不同。本文的主要贡献如下:

- 据我们所知，这是首项研究各国态度并对其进行聚类的工作

  各国在 Twitter 上对乌克兰战争的看法。

- 本文提出了一种新方法，用于对各国的情感时间序列进行建模和聚类。

本文其余部分安排如下：第 2 节回顾以往研究。第 3 节介绍所提出的方法。第 4 节说明实施过程和研究结果。最后，第 5 节总结结论与局限性。

2- 相关研究

随着社交网络的不断发展和普及，它们已成为了解用户在各个领域态度的重要且有价值的信息来源。分析社交网络用户发布的这些非结构化文本信息，需要运用大数据和自然语言处理等技术。Twitter 是最受欢迎的社交网络之一，用户可以在其上分享对时事和议题的想法与感受（Mathur、Kubde 和 Vaidya，2020年）。研究人员已在多个领域对用户观点进行了大量分析，包括政治（Ansari、Aziz、Siddiqui、Mehra 和 Singh，2020年）、股票收益预测（Sul、Dennis 和 Yuan，2017年）、可持续能源（Corbett 和 Savarimuthu，2022年）以及旅游业（Abbasi-Moud、Vahdat-Nejad 和 Mansoor，2019年；Asani、Vahdatnejad、Hosseinabadi 和 Sadri，2020年）。例如，过去几年 COVID-19 疫情蔓延期间，研究人员分析了与 COVID-19 相关推文中的情感（Salmani 等，2021年；Vahdat-Nejad 等，2022年），并提取了讨论的主要话题（Azizi、Vahdat-Nejad、Hajiabadi 和 Khosravi，2021年）。

战争和冲突的发生，是促使用户在社交网络上发表观点的原因之一。关于这一点，各国用户对近期事件的看法

研究者分析了2021年8月至11月期间人们对阿富汗局势的看法（Aggarwal 等人，2022年）。为此，研究调查了推文数量最多的八个国家。研究发现之一是，包含恐怖分子、袭击、破坏和暴力等负面词语的推文数量很多；此外，八个受调查国家对阿富汗近期局势的看法也都相似（Aggarwal 等人，2022年）。同样，研究者对2017年4月有关叙利亚内战的英文推文和土耳其语推文进行了情感分析（正面、中性、负面、非常正面和非常负面）（Öztürk 和 Ayvaz，2018年）。研究使用 R-Sentiment 软件包分析英语推文的情感。由于大量叙利亚难民涌入土耳其，研究者也分析了土耳其语推文。由于当时没有针对土耳其语推文的情感分析模型，研究者编制了一份土耳其语词汇情感词典。结果显示，土耳其语推文中正面推文数量较多，而英文推文中中性、负面和极负面推文数量较多。此外，英文推文的政治色彩更浓，也更多关注移民的合法性；而土耳其语推文则更关注战争的具体情况，因为土耳其社群关注邻近土耳其边境发生的冲突（Öztürk 和 Ayvaz，2018年）。研究者还针对有关叙利亚化学战的推文数量最多的十个国家开展了类似的情感分析（Bashir 等人，2021年）。总体而言，负面推文占比更高，表明用户对叙利亚化学袭击持负面看法（Bashir 等人，2021年）。

俄乌战争是2022年最重要的事件之一，围绕这一事件发布了无数推文。近期，研究人员分析了中国微博文本，以提取中国用户对这场冲突讨论的主要话题（Chen 等人，2022）。我们希望通过对各个国家的情感趋势进行建模和聚类，继续这项研究。据我们所知，

目前尚无研究调查并分类不同国家用户对这场战争的情感趋势。

3- 提出的方法

有关俄乌战争的推文数量众多，而这场战争是2022年最重大的事件之一。据我们所知，目前尚无研究分析与这场战争相关的推文情感，也未对来自不同国家的用户情感进行考察和分类。本研究旨在收集并分析有关乌克兰争端的推文，以便对不同国家用户的情感趋势进行分类，并探究其随时间的变化。

3-1- 推文收集与处理

2022年3月，乌克兰与俄罗斯之间的战争是推文的热门话题。首先，收集与乌克兰战争相关的推文，并按地点进行分类。随后，使用情感分析识别正面和负面推文。最后，对推文情感的时间序列进行聚类。

我们使用关键词 Ukraine 收集了2022年3月期间与俄乌战争相关的14万条英文推文。随后，利用地理标签区分来自不同国家的推文。因此，删除了位置未知的推文。

判断一条推文是正面、负面还是中性的过程称为推文情感分析。许多情感分析研究都以社交网络帖子为研究对象，例如 Twitter 上的帖子，因为这些帖子包含用户的观点和感受。我们利用情感分析来确定战争期间公众情绪趋势随时间的变化。为了计算推文的情感分数，我们采用了颇具潜力的语言模型 RoBERTa

（Liu 等人，2019年）模型。RoBERTa（Liu 等人，2019年）由 Google 推荐，是语言模型 BERT（Devlin、Chang、Lee 和 Toutanova，2019年）的优化版本。识别正面和负面推文，有助于我们了解公众对乌克兰冲突的观点走向。随后，我们按周统计了每个国家（推文数量充足的国家）的正面和负面推文数量，从而为每个国家生成时间序列。对各国时间序列进行分析和聚类，揭示了有关公众舆论的有趣信息。

3-2- 国家情感趋势的聚类

已有多种方法用于对社交网络中用户的观点进行建模和聚类（Asadolahi、Akbari、Hesamian 和 Arefi，2021年；G. Hesamian 和 M. Akbari，2021年；Hesamian 和 Akbari，2018年；G. Hesamian 和 M. G. Akbari，2021年；Hesamian 和 Akbari，2022年）。本研究采用邻域平均法对国家进行聚类。由于不同国家的推文数量各不相同，且其中多数差异显著，因此首先对每个国家的每周数据进行归一化处理。随后，计算每个国家每周正面和负面推文数量的频率。因此，针对战争爆发后的前四周，计算每个国家对应的四个正面频率和四个负面频率，并将其建模为一个包含八个特征的向量。然后，使用邻域平均法对所提出模型为各国得出的系数进行聚类。国家之间的距离采用欧几里得距离计算，距离较近的国家归入同一聚类。下文将详细介绍采用支持向量法（SVM）的所提出模型。

首先，我们考虑以下时间数据模型 $\{Z_t\colon t = 1,2,\dots,T \ (\mathrm{T} = 8)\}$：

$$Z_t = \sum_{j=1}^{p} W_j Z_{t-j} + W_0 = \overrightarrow{W}^T \overrightarrow{Z_t} + W_0 \qquad \vec{Z}_t = (Z_{t-1}, \dots, Z_{t-p})$$

为了估计向量 $\vec{w}$ 和 w_0，我们根据图1和以下方程使用支持向量机：

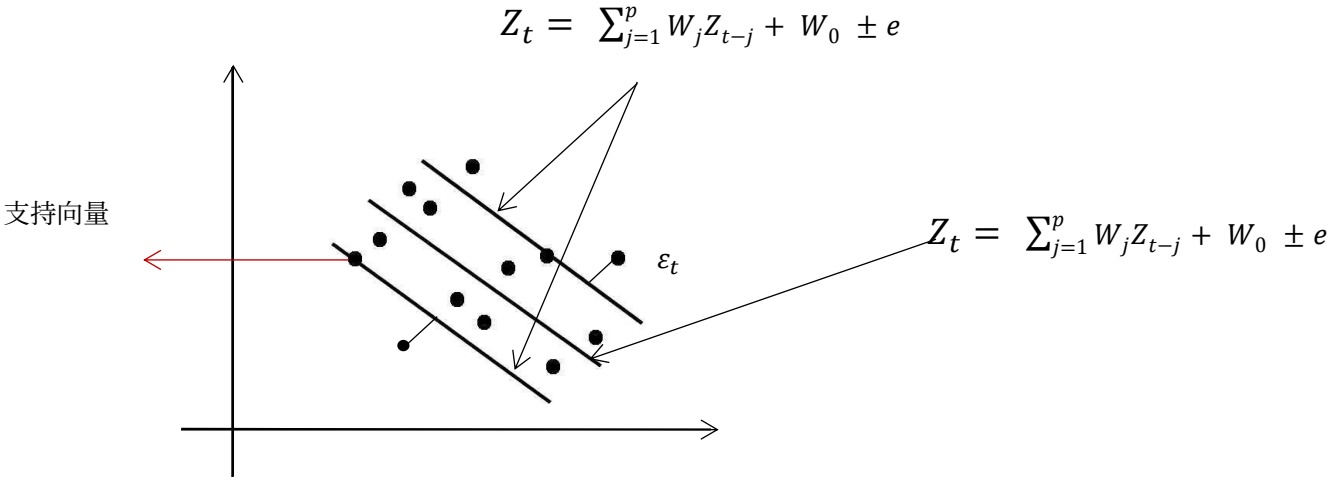

图 1. 使用支持向量机进行估计

$$\min_{\overrightarrow{W},W_0,\vec{\varepsilon},\vec{\varepsilon}^*} J(\overrightarrow{W}, W_0, \vec{\varepsilon}, \vec{\varepsilon}^*) = \frac{1}{2} \overrightarrow{W}^T \overrightarrow{W} + c \sum_{t=p+1}^{T} (\varepsilon_t + \varepsilon_t^*) \qquad (1)$$

S.T

$$Z_t - \overrightarrow{W}^T \overrightarrow{Z_t} - W_0 \leq e + \varepsilon_t \qquad t = p+1, \dots, T$$

$$\overrightarrow{W}^T \overrightarrow{Z_t} + W_0 - Z_t \leq e + \varepsilon_t^* \qquad t = p+1, \dots, T$$

$$\varepsilon_t, \varepsilon_t^* \geq 0$$

上述优化问题中，系数为 $\alpha_t, \alpha_t^*, \mu_t, \mu_t^*$ 时的拉格朗日方程如下：

$$L\left(\overrightarrow{W}, W_0, \vec{\varepsilon}, \vec{\varepsilon}^*, \vec{\alpha}, \vec{\alpha}^* \mu, \vec{\mu}^*\right)$$

$$= J\left(\overrightarrow{W}, W_0, \vec{\varepsilon}, \vec{\varepsilon}^*\right)$$

$$- \sum_{t=p+1}^{T} \alpha_t \left(e + \vec{\varepsilon} - Z_t + \overrightarrow{W}^T \overrightarrow{Z_t} + W_0\right)$$

$$- \sum_{t=p+1}^{T} \alpha_t^* \left(e + \vec{\varepsilon}^* + Z_t - \overrightarrow{W}^T \overrightarrow{Z_t} - W_0\right) - \sum_{t=p+1}^{T} \left(\mu_t \varepsilon_t + \mu_t^* \varepsilon_t^*\right) \qquad (2)$$

其中，将 L 代入公式 (2)，即可得到公式 (1) 中的最优值 J，即：

$$\max(\vec{\alpha}, \vec{\alpha}^*, \vec{\mu}, \vec{\mu}^*) \qquad \min\left(\overrightarrow{W}, W_0, \vec{\varepsilon}, \vec{\varepsilon}^*\right) \qquad L\left(\overrightarrow{W}, W_0, \vec{\varepsilon}, \vec{\varepsilon}^*, \vec{\alpha}, \vec{\alpha}^* \mu, \vec{\mu}^*\right)$$

我们有：

$$\frac{\partial L}{\partial \overrightarrow{W}} = 0 \ \rightarrow \overrightarrow{W} = \sum_{t=p+1}^{T} \left(\alpha_t - \alpha_t^*\right) Z_t$$

$$\frac{\partial L}{\partial W_0} = 0 \ \rightarrow \sum_{t=p+1}^{T} \left(\alpha_t - \alpha_t^*\right) = 0 \qquad (3)$$

$$\frac{\partial L}{\partial \varepsilon_t} = 0 \ \rightarrow \ c - \alpha_t - \mu_t = 0 \qquad \frac{\partial L}{\partial \varepsilon_t^*} = 0 \ \rightarrow c - \alpha_t^* - \mu_t^* = 0$$

将式 (3) 代入式 (2)，可得对偶问题 (1) 如下：

$$\max_{\vec{\alpha},\vec{\alpha}^*} J_D(\alpha,\alpha^*)$$

$$= -\frac{1}{2}\,\vec{W}^{\,T}\vec{W}$$

$$-e\sum_{t=p+1}^{T}(\alpha_t+\alpha_t^*)$$

$$+\sum_{t=p+1}^{T}Z_t(\alpha_t-\alpha_t^*)$$

$$=\sum_{t=p+1}^{T}\sum_{k=p+1}^{T}(\alpha_t-\alpha_t^*)(\alpha_k-\alpha_k^*)\quad \overrightarrow{Z_t}^{\,T}\overrightarrow{Z_k}$$

$$-e\sum_{t=p+1}^{T}(\alpha_t+\alpha_t^*)+\sum_{t=p+1}^{T}Z_t(\alpha_t-\alpha_t^*)$$

S.T

$$\sum_{t=p+1}^{T}(\alpha_t-\alpha_t^*)=0 \qquad 0\le\alpha_t,\alpha_t^*\le c$$

使用KKT方法得到W_0，如下所示:

$$\alpha_t\left(e+\varepsilon_t-Z_t+\overrightarrow{W}^{\,T}\overrightarrow{Z_t}+W_0\right)=0$$

$$\alpha_t^*\left(e+\varepsilon_t^*+Z_t-\overrightarrow{W}^{\,T}\overrightarrow{Z_t}-W_0\right)=0$$

因此，经过几项简单计算，我们得到:

$$W_0=Z_t-\overrightarrow{W}^{\,T}\overrightarrow{Z_t}-e \qquad \alpha_t\epsilon[0,c] \qquad \varepsilon_t=0$$

$$W_0=Z_t-\overrightarrow{W}^{\,T}\overrightarrow{Z_t}+e \qquad \alpha_t^*\epsilon[0,c] \qquad \varepsilon_t^*=0$$

因此：

$$\widehat{W_0} = \frac{1}{|S|}\sum_{t\epsilon S}\left(Z_t - \overrightarrow{W}^T\overrightarrow{Z_t} - Sign(\alpha_t - \alpha_t^*)e\right)$$

$$S = \{t:\ 0 < \alpha_t - \alpha_t^* < c\}$$

如果是这样，我们就会得到：

$$\widehat{Z_t} = \sum_{k=p+1}^{T}(\hat{\alpha}_k - \hat{\alpha}_k^*)\overrightarrow{Z_k}^T\overrightarrow{Z_t} + \widehat{W}_0$$

现在，如果我们令 $Z_t = \vec{W}^T\varphi(\vec{Z}_t) + W_0$ 其中 φ：$R^p \to R^n$，那么同样可以得到：

$$\widehat{Z_t} = \sum_{k=p+1}^{T}(\alpha_k - \alpha_k^*)\ \varphi^T\left(\vec{Z}_k\right)\varphi\left(\vec{Z}_t\right) = \sum_{k=p+1}^{T}(\alpha_k - \alpha_k^*)\ K\left(\vec{Z}_k, \vec{Z}_t\right) \qquad (4)$$

其中 k 是一个核函数。我们不采用模型 (4)，而考虑以下模型：

$$Z_t = \sum_{j=p+1}^{T} W_j\ K_h(\vec{Z}_j, \vec{Z}_t) + W_0$$

该模型具有许多特征，包括：

- 目标方程由支持向量机方法推导得出。
- 我们不使用误差 $\varepsilon_t, \varepsilon_t^*$，而是使用损失函数 ρ 来估计系数。
- 模型中的对偶方程使用核函数 K_h。
- 编程求解上述方程的系数值时，所需的时间调整较少。

- 平滑常数可通过试错法或广义瓦瑟曼交叉验证准则计算。

- 损失函数中平滑常数 h 的最优值使得我们能够考虑线性或非线性Z_t 模式下的许多离群数据和变化。

所有通过函数 $\sum_{j=p+1}^{T} W_j\ K_h(\vec{Z}_j, \vec{Z}_t)$ 获得的 Z_p，……， Z_{p+1} 观测值均用于估计 Z_t；该函数是以中心 Z_t 和半径 h 为邻域的加权和。此外，h 是通过广义交叉验证准则获得的平滑常数。此外，我们使用以下目标方程来获得 W_0 和 $\vec{W}$:

$$\left(\widehat{W}, W_0\right) = \min_{\vec{W}, W_0} \frac{\vec{W}^{\,T} W}{2} + c \sum_{t=p+1}^{T} \rho(Z_t - \sum_{j=p+1}^{T} W_j\ k\ (\vec{Z}_j, \vec{Z}_t))$$

，其中 ρ 是损失函数。

均方误差（ρ_{LS}）用于衡量预测值与实际值之间的距离，是时序数据分析与建模中最知名、应用最广泛的损失函数之一。有时，数据的排列方式会使预测值趋向于离群数据，形成所谓的“偏斜”情况。在这种情况下，上述损失函数会导致参数估计和响应变量预测出现问题。Huber损失函数（ρ_H）可用于解决此类问题。在大多数涉及真实世界数据的建模问题中，我们必须确定预测是确定的还是不确定的。了解预测值的变化范围，对于解决现实问题至关重要。使用分位数损失函数（ρ_Q）的特点是，它为响应变量提供一个区间作为预测，而非某个具体数值。上述函数的形式汇总于表1。

表1。损失函数

方法	损失函数
最小二乘法	$\rho_{LS}(e) = e^2$
Huber	$\rho_H(e) = \begin{cases} \frac{1}{2}e^2 & for \lvert e\rvert \le k \\ k\lvert e\rvert - \frac{1}{2}k^2 & for \lvert e\rvert > k \end{cases}$
分位数	$\rho_Q(e) = e(Q - I_{(e<0)}), \quad 0 \le Q \le 1$

4-评估

该数据集包含 140,000 条与俄乌战争相关的推文，这些推文是在战争爆发后的第一个月（2022年3月）使用关键词 Ukraine 收集的。所有实现均使用 Python 编程语言。研究使用地理标签确定各国发布的推文，并对各国推文进行了情感分析。在此阶段，为避免重复，删除了转推。图2展示了战争最初四周内各国正面和负面情绪推文的频数。在所有国家，负面推文的数量都超过正面推文的数量，这表明用户对乌克兰冲突持负面看法。此外，分享了足够数量冲突相关推文的国家中，欧洲国家所占比例较高，占国家总数的50%。亚洲国家位居第二，约占国家总数的30%。瑞士、新加坡、葡萄牙、乌克兰、西班牙、意大利、奥地利和土耳其的负面推文与正面推文之比较高，表明这些国家对相关事件的态度更为负面

俄乌战争。相比之下，比利时、丹麦、中国、阿根廷、菲律宾和瑞典的正面与负面推文比率较高。这一比率表明，在冲突发生的第一个月，这些国家公民的意见较少负面。

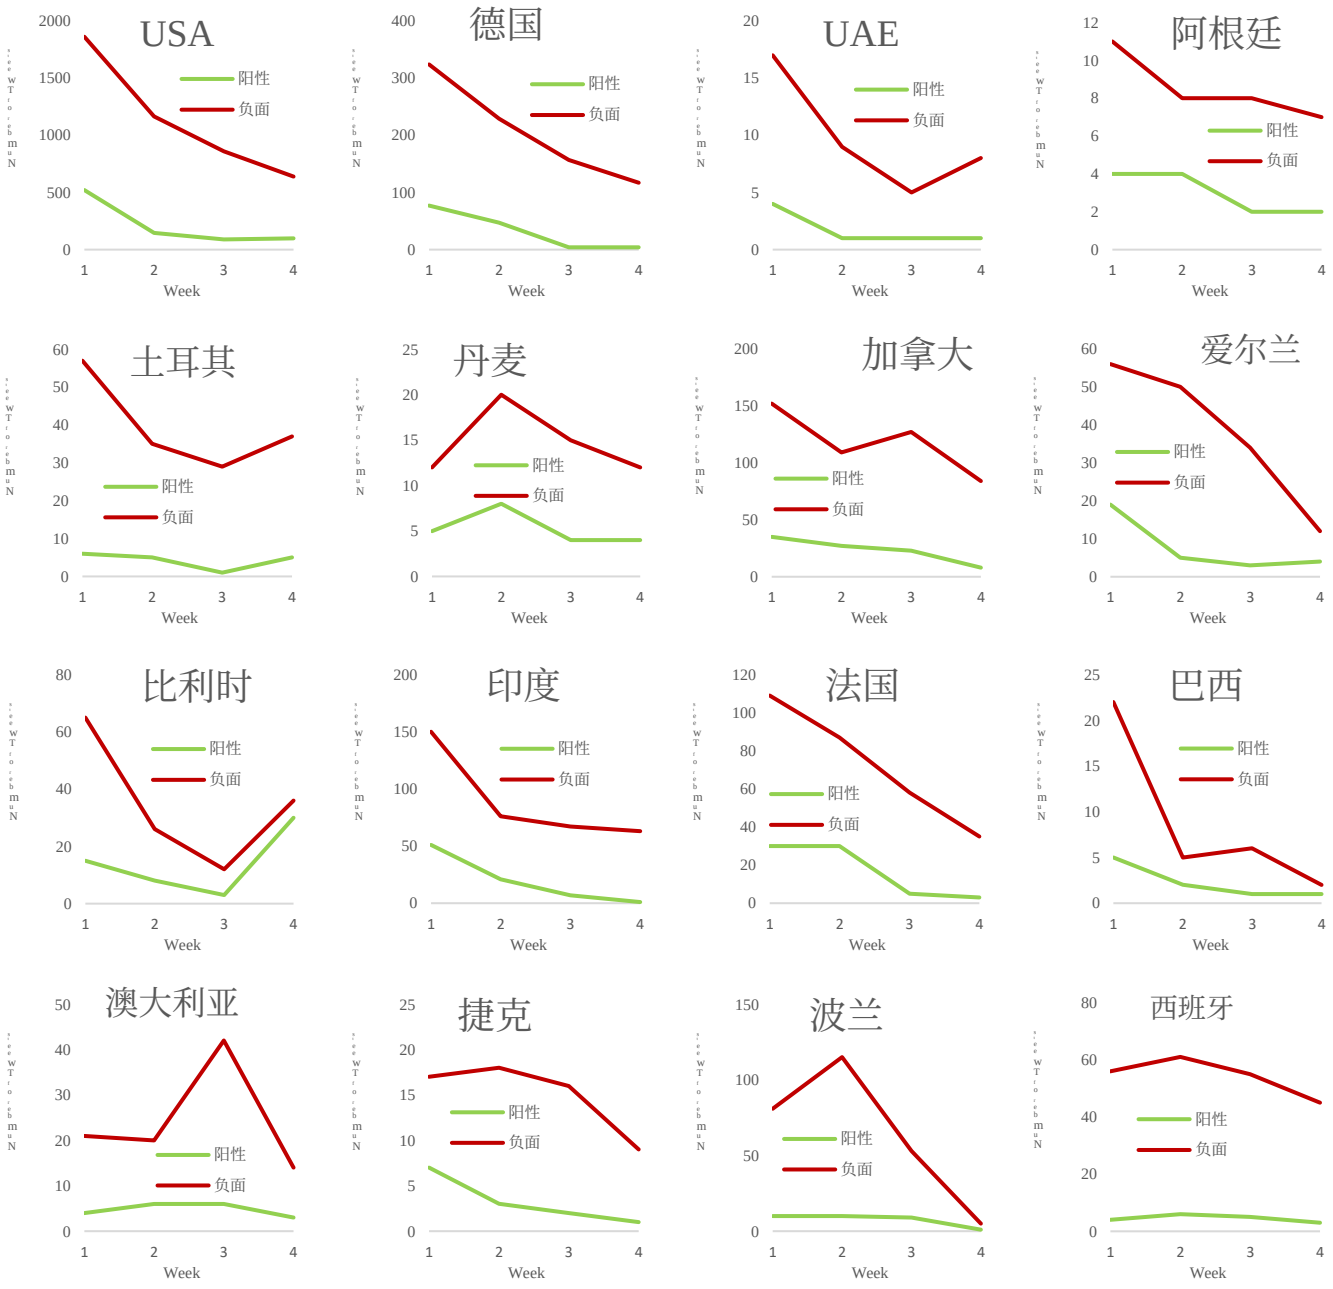

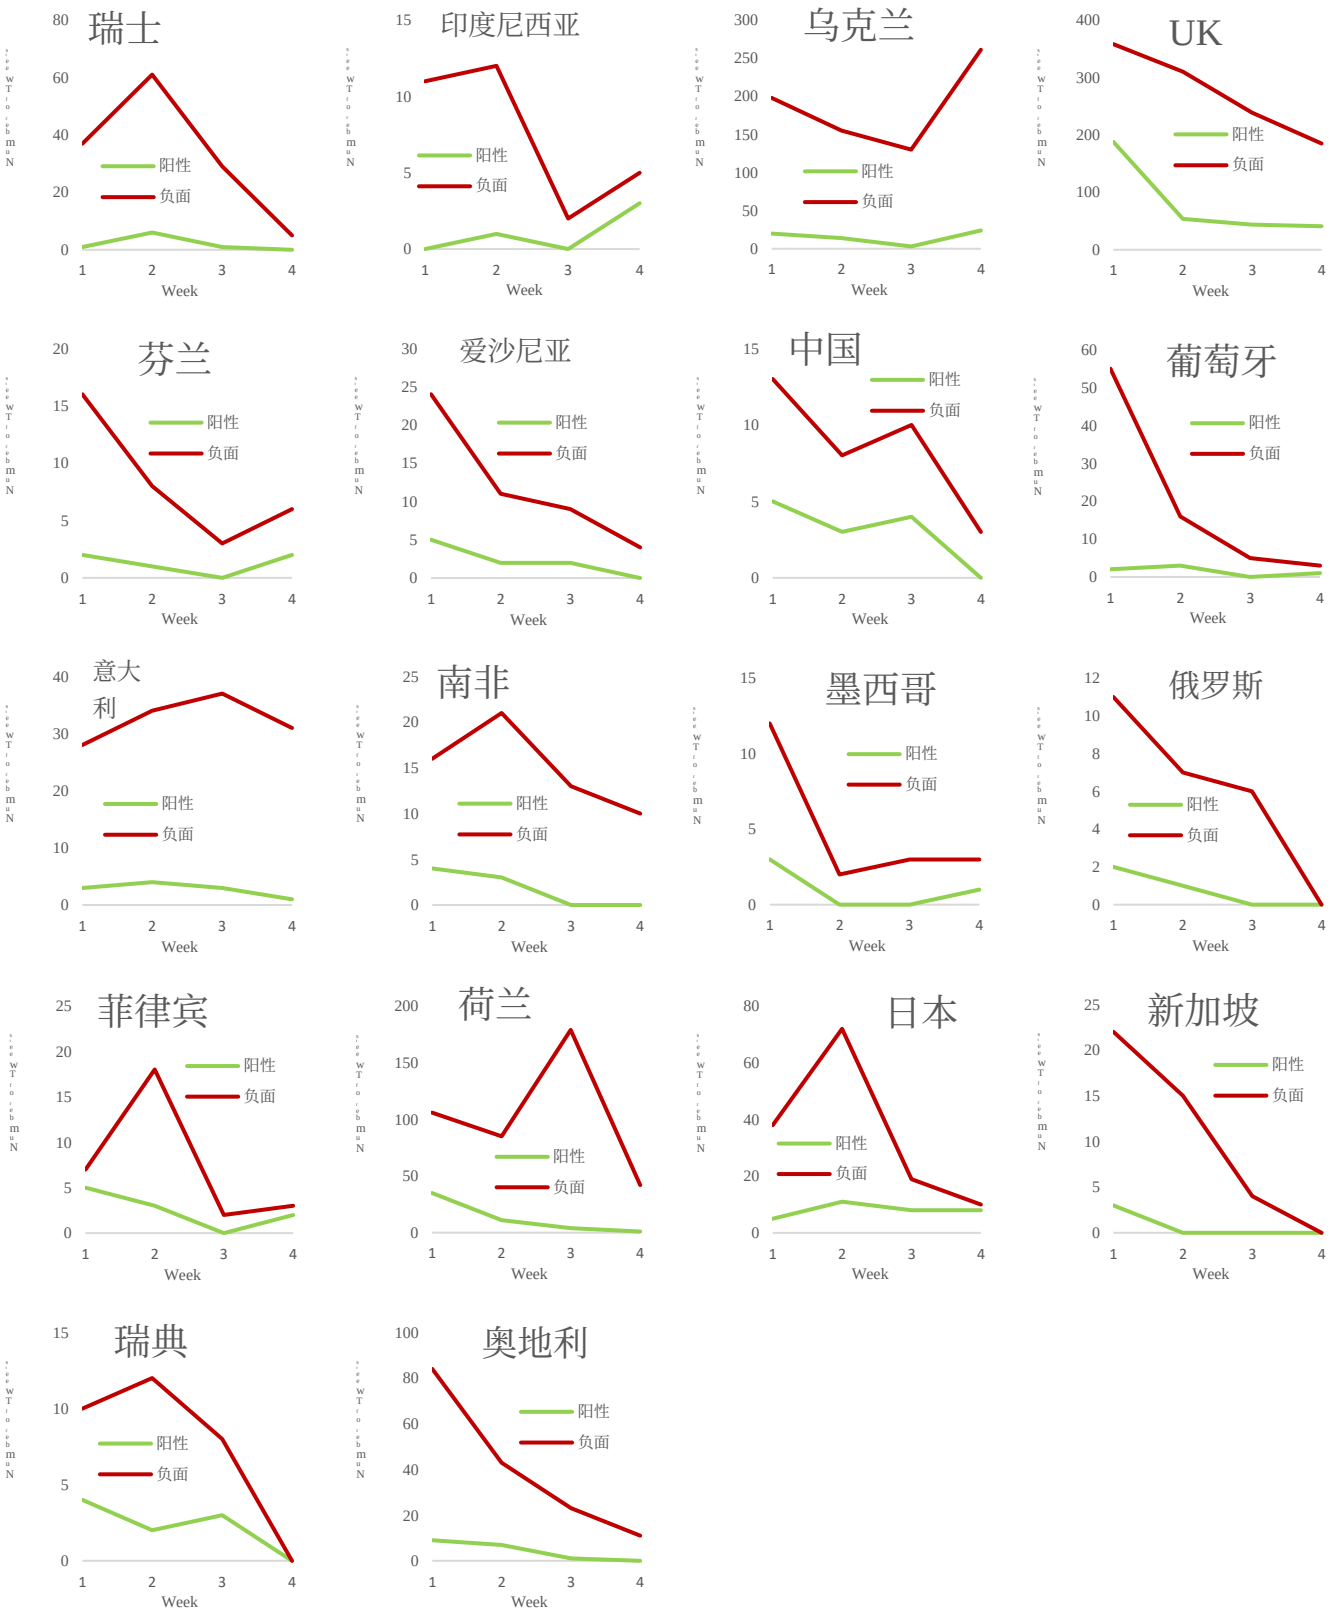

图2. 战争前四个月正面和负面推文的频率

1-4- 国家时间序列聚类

所提出的聚类模型应用于推文数量最多的 34 个国家。这 34 个国家最终被划分为五个集群。图 3 展示了各国的聚类结果。集群 1 和集群 5 中的国家数量最多。集群 1 包括美国、加拿大、英格兰、印度以及大多数西欧国家。除印度外，其他国家在战争期间都全面支持乌克兰。集群 2 仅包含乌克兰。考虑到该国遭到袭击，其对这场战争的态度与其他国家不同也就不足为奇了。

尽管日本政府制裁了俄罗斯，但日本的模型结果却出人意料地与其他任何国家都不同。集群 4 由澳大利亚、意大利和西班牙组成。最后，集群 5 包括阿拉伯联合酋长国、爱沙尼亚、俄罗斯、新加坡、芬兰、葡萄牙、巴西、阿根廷、墨西哥、中国、丹麦、比利时、捷克共和国、波兰、南非、瑞士、菲律宾和瑞典，这些国家对俄罗斯的观点都相对相似 。这些国家大多位于亚洲、非洲南部和中部、东欧以及斯堪的纳维亚。在解读聚类结果时，必须考虑以下两点，这也反映了本研究的局限性：

- 国家的聚类是根据 用户的推文在战争第一个月的

  战争期间。当然，随着战争持续以及其他事件的发生，聚类类型可能会发生变化。

- 对正面和负面推文时间序列的动态趋势进行了聚类。因此，

  时间参数以及该主题随时间推移的重要性也在某种程度上被纳入其中。

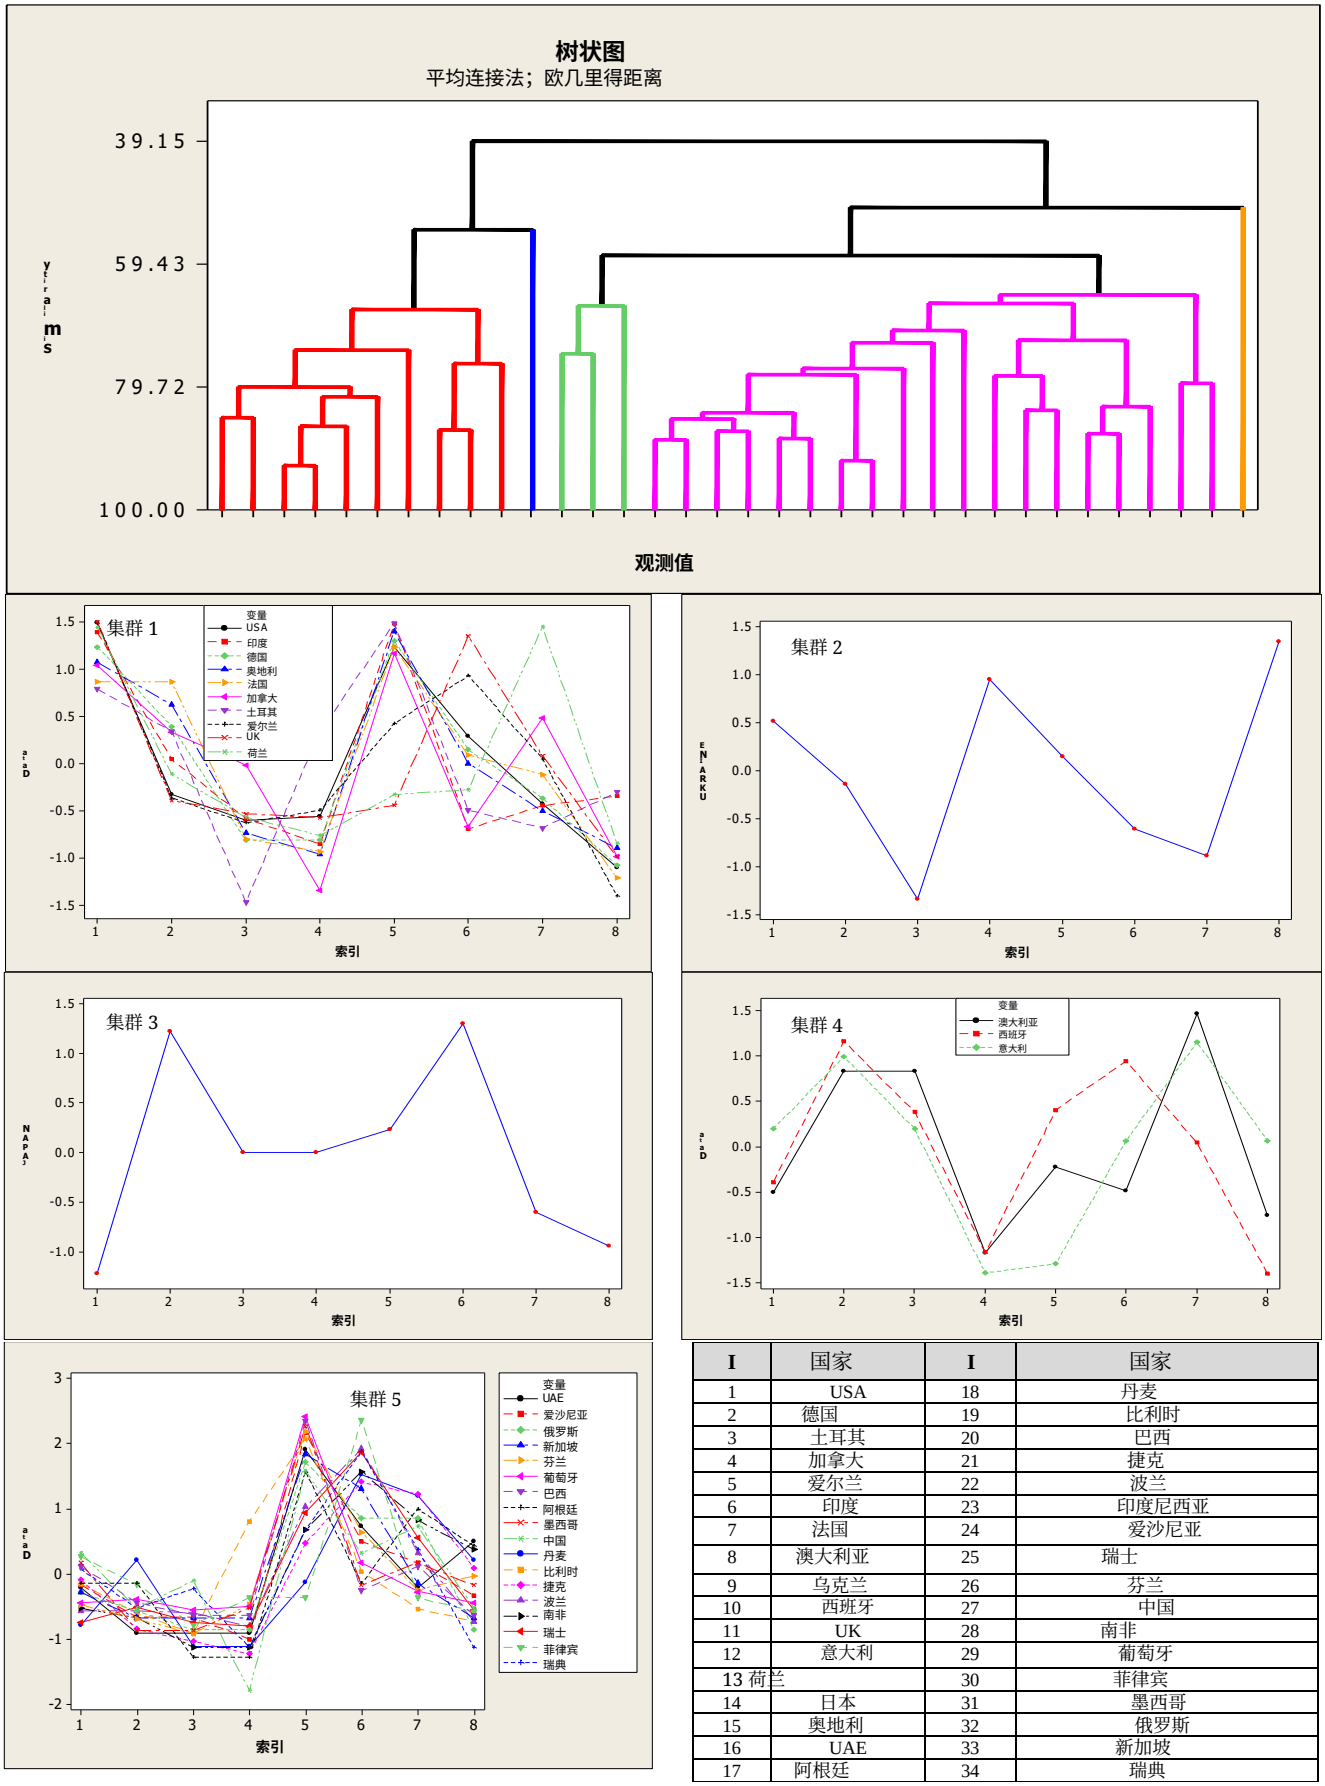

I	国家	I	国家
1	USA	18	丹麦
2	德国	19	比利时
3	土耳其	20	巴西
4	加拿大	21	捷克
5	爱尔兰	22	波兰
6	印度	23	印度尼西亚
7	法国	24	爱沙尼亚
8	澳大利亚	25	瑞士
9	乌克兰	26	芬兰
10	西班牙	27	中国
11	UK	28	南非
12	意大利	29	葡萄牙
13	荷兰	30	菲律宾
14	日本	31	墨西哥
15	奥地利	32	俄罗斯
16	UAE	33	新加坡
17	阿根廷	34	瑞典

图 3. 基于邻域平均值对 34 个国家进行聚类

5. 结论

本文考察了俄乌冲突爆发首月期间用户对这场冲突的情感。为此，研究人员于2022年3月通过关键词“乌克兰”收集了14万条相关英文推文。随后，根据每条推文的地理标签确定其位置。研究采用了RoBERTa模型，这是一种基于语言的模型，其性能优于类似模型，用于分析推文的情感。之后，研究分析了推文数量充足的国家每周正面和负面推文数量的时间序列。这些时间序列的分析揭示了用户对俄乌冲突观点的重要见解。由于所有国家的负面推文数量都多于正面推文，因此可以得出较为可靠的结论：大多数用户对这场战争持负面看法。

此外，研究还对各国正面和负面推文的趋势进行了聚类，以反映该议题随时间变化的重要性。本研究结果使我们能够关注到战争爆发首月期间，美国、加拿大和西欧用户观点的相似性，以及东欧、南美洲、亚洲和斯堪的纳维亚用户观点的相似性。此外，乌克兰和日本用户的观点各具特点，与其他任何国家的用户都不同。

本文的局限之一是未考虑英语以外语言的推文，因为许多国家的用户英语并不流利，会使用其他语言发布推文。此外，我们仅使用 Twitter 进行数据采集，未纳入其他社交网络。最后，我们只收集了包含关键词“乌克兰”的推文，因此可能未能捕获所有相关推文。

在未来的研究中，可以采用多种方法对所提出模型为各个国家得出的系数进行聚类，并比较结果。此外，还可以从社交网络用户的视角分析这场战争对

国际关系以及经济、政治和其他问题的影响。

参考资料

Abbasi-Moud, Z., Vahdat-Nejad, H., & Mansoor, W.（2019年）。通过情感分析探测智慧城市中的游客偏好。论文发表于全球物联网大会，阿拉伯联合酋长国迪拜，阿拉伯联合酋长国。Aggarwal, S., Khan, S. S., & Kakkar, M.（2022年）。利用文本挖掘分析各国对阿富汗近期事件的观点。论文发表于第十二届云计算、数据科学与工程国际会议，印度。Ansari, M. Z., Aziz, M., Siddiqui, M., Mehra, H., & Singh, K.（2020年）。分析 Twitter 上的政治情感倾向。论文发表于计算智能与数据科学，印度。Asadolahi, M., Akbari, M. G., Hesamian, G., & Arefi, M.（2021年）。一种具有精确预测变量和模糊响应的稳健支持向量回归。《近似推理国际期刊》，132(1)，206-225。Asani, E., Vahdatnejad, H., Hosseinabadi, S., & Sadri, J.（2020年）。通过情感分析提取用户的食物偏好。论文发表于第八届伊朗模糊与智能系统联合大会，伊朗马什哈德，伊朗。Azizi, F., Vahdat-Nejad, H., Hajiabadi, H., & Khosravi, M. H.（2021年）。提取与 COVID-19 相关推文的主要主题。论文发表于计算机工程与知识国际会议，伊朗。Bashir, S., Bano, S., Shueb, S., Gul, S., Mir, A. A., Ashraf, R., & Noor, N.（2021年）。叙利亚人民的 Twitter 啁啾：对叙利亚化学袭击相关推文进行情感分析。《国际灾害风险削减期刊》，62，102397。Briskilal, J., & Subalalitha, C.（2022年）。一种利用 BERT 和 RoBERTa 对习语和字面文本进行分类的集成模型。《信息处理与管理》，59(1)，102756。Chen, B., Wang, X., Zhang, W., Chen, T., Sun, C., Wang, Z., & Wang, F.-Y.（2022年）。俄乌战争期间网络空间中的舆论动态：基于中国微博的案例分析。《IEEE计算社会系统汇刊》，9(3)，948 - 958。Corbett, J., & Savarimuthu, B. T. R.（2022年）。从推文到见解：对美国可持续能源情感话语的社交媒体分析。《能源研究与社会科学》，89，102515。Crannell, W. C., Clark, E., Jones, C., James, T. A., & Moore, J.（2016年）。对美国癌症患者情绪进行模式匹配的 Twitter 分析。《外科研究杂志》，206，536-542。Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K.（2019年）。BERT：用于语言理解的深度双向变换器预训练。论文发表于北美计算语言学协会：人类语言技术分会，美国。Eisenstein, J.（2018年）。自然语言处理 Hesamian, G., & Akbari, M.（2021年）。具有精确预测变量和模糊响应的支持向量逻辑回归模型。《环境智能与人性化计算杂志》，1(1)，1-12。Hesamian, G., & Akbari, M. G.（2018年）。基于模糊数据的时间序列半参数模型。《IEEE模糊系统汇刊》，26(5)，2953-2966。Hesamian, G., & Akbari, M. G.（2021年）。用于模糊预测时间序列数据的非参数模型。《计算与应用数学》，40(4)，1-21。Hesamian, G., & Akbari, M. G.（2022年）。基于三角模糊随机变量的自回归时间序列模型模糊分位数方法。《计算与应用数学》，41(3)，1-20。Jamalian, M., Vahdat-Nejad, H., & Hajiabadi, H.（2022年）。利用社交网络挖掘研究 COVID-19 对教育的影响。arXiv 预印本 arXiv:2203.06584。Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., . . . Stoyanov, V.（2019年）。RoBERTa：一种稳健优化的 BERT 预训练方法。arXiv 预印本 arXiv:1907.11692。Mathur, A., Kubde, P., & Vaidya, S.（2020年）。疫情期间利用 Twitter 数据进行情绪分析：COVID-19。论文发表于通信与电子系统，印度。Öztürk, N., & Ayvaz, S.（2018年）。Twitter 情感分析：针对叙利亚难民危机的文本挖掘方法。《远程信息处理与信息学》，35，136-147。Salmani, F., Vahdat-Nejad, H., & Hajiabadi, H.（2021年）。从用户评论的角度分析 COVID-19 对经济的影响。论文发表于计算机工程与知识国际会议，伊朗。Sul, H. K., Dennis, A. R., & Yuan, L.（2017年）。在 Twitter 上交易：利用社交媒体情感预测股票收益。《决策科学》，48，454-488。

Vahdat-Nejad, H., Salmani, F., Hajiabadi, M., Azizi, F., Abbasi, S., Jamalian, M., . . . Hajiabadi, H.（2022年）。通过社交网络挖掘提取人们对 COVID-19 的感受。《信息与知识管理期刊》，1，2240008。
Zad, S., Heidari, M., Jones, J. H., & Uzuner, O.（2021年）。文本数据概念级情感分析技术综述。论文发表于 IEEE 世界人工智能与物联网大会线上会议。