

# 基于深度学习的核武器数量预测

王彩玲<sup>1</sup> 张智栋<sup>1</sup>

WANG Cailing ZHANG Zhidong

## 摘要

核武器是指利用能自身持有进行的原子核裂变或聚变反应瞬时释放的巨大的能量,产生爆炸作用,并具有大规模毁伤破坏效应的武器。核武器的出现改变了传统战争的规模和样式,对人类和地球上生物的生存和发展产生了深远的影响。为了维护国家安全和世界和平,准确预测世界各国核武器数量以评估各国军事力量是十分必要的。核武器数量的变化是多因素影响的结果,变化趋势复杂,难以预测。对此,提出一种基于双向 LSTM 网络的核武器数量预测模型。实验选择了中国、法国、俄罗斯、英国、美国和以色列六个国家 1938 年至 2023 年核武器数据作为研究对象,对原始数据进行预处理和相关性分析,构建了双向 LSTM 模型进行拟合预测,利用可视化技术分析预测结果,调节参数并进一步优化模型。实验选择 R<sup>2</sup>、MAE 和 RMSE 作为评估指标,分别为:0.863 5、14.418 8 和 17.714 4。结果表明,双向 LSTM 模型预测结果优于 Prophet 模型,这证明了所构建的双向 LSTM 模型的有效性。

## 关键词

核武器;双向 LSTM 模型;Prophet 算法;时序序列预测;相关性分析

doi: 10.3969/j.issn.1672-9528.2024.06.002

## 0 引言

第二次世界大战时期,美国在日本广岛投下了第一颗名为“小男孩”的原子弹,炸死了近 20 万人,并摧毁了广岛所有建筑物。这是人类历史上第一次将原子弹付诸实践,也是许多国家第一次认识到原子弹的可怕威力<sup>[1]</sup>。战争结束后,一些国家前仆后继地对核武器进行了研发与试验,希望早日掌握这一拥有巨大威力的武器<sup>[2-3]</sup>。美国和俄罗斯通过科技和军备竞赛、太空竞赛、外交竞争等方式进行对抗,双方战术核武器数量急剧增加。自冷战结束后,美国战术核武器库存量已经从 2 万~3 万枚下降到如今的约 2500 枚数量级<sup>[4]</sup>。俄罗斯在削减战术核武器的数量方面也同样引人注目,从 20 世纪 80 年代末的 1.3 万至 2.2 万枚减少到今天的不到 2000 枚。库存量的减少并不能减少它的杀伤力。因此,为了维护国家安全和世界和平,需要准确预测各国核武器的数量。核武器数量受到各国政治、军事、科技、经济等多个因素的影响<sup>[5-10]</sup>。从 20 世纪 60 年代到 21 世纪初,核武器数量处于上升趋势,而后逐渐下降。同时,各国战略与战术核武器数量也呈现此消彼长的态势。此外,由于各国国情不同,准确预测其数量

是十分困难的。

传统的数据预测方法通常基于统计学原理和经验规则进行手动特征提取,这需要大量的先验知识,并增加了处理数据的时间。此外,该方法往往适用于简单的线性关系数据,在面对复杂的非线性关系数据时会导致较大的误差。随着深度学习技术的发展,神经网络模型具有强大的自适应和自学习能力,可以从大规模数据中提取高级特征表示,并且能够对复杂的非线性关系进行建模。因此,采用基于深度学习的预测方法可以有效提高复杂数据预测的准确性。

为了准确预测核武器数量的变化趋势,本文将采用双向 LSTM 预测模型和 Prophet 时间序列模型分别对 1938 至 2003 年的核武器数据进行拟合,并对之后 2004 至 2023 年的核武器数量进行预测分析。最后,计算两种模型的 R 平方 (R-squared,  $R^2$ )、均方根误差 (root mean squared error, RMSE) 和平均绝对误差 (mean absolute error, MAE),分析预测结果并评估模型预测的精度。

## 1 相关技术研究

### 1.1 双向 LSTM 网络

长短期记忆网络 (long short term memory networks, LSTM) 是循环神经网络 (recurrent neural network, RNN) 的一种变体,可以有效解决传统循环神经网络中的梯度消失和梯度爆炸问题<sup>[11]</sup>。LSTM 包括记忆单元状态 (state)、遗

1. 西安石油大学计算机学院 陕西西安 710065

[基金项目] 陕西省自然科学基金面上项目 (2022JM-396); 陕西省重点研发计划项目 (2023-YBSF-437); 国家自然科学基金资助项目 (31160475, 61401439)

忘门 (forget gate)、输入门 (input gate) 和输出门 (output gate)。其中, 记忆单元状态用来存储每一个时间戳中的信息。遗忘门  $f_t$  控制上一个时间戳的记忆单元  $c_{t-1}$  丢弃无效信息。输入门  $i_t$  控制上一个时间戳的记忆单元  $\tilde{c}_t$  存储有效信息。输出门  $o_t$  控制下一时间戳记忆单元状态输出到外部状态  $h_t$ 。LSTM 循环单体如图 1 所示, 其中,  $x_t$  为当前时间戳的输入,  $\sigma$  为 sigmoid 函数,  $\tanh$  为双曲正切函数。

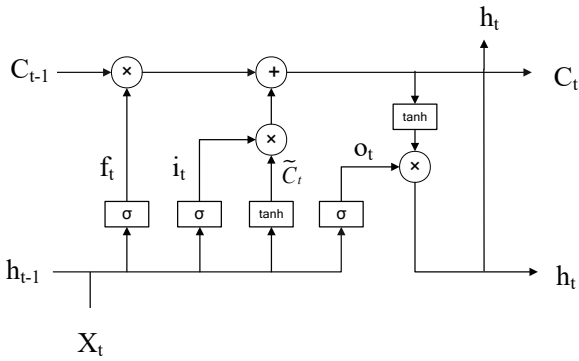


图 1 LSTM 单体网络结构

双向 LSTM 网络包含两个独立的 LSTM 隐藏层 (Forward Layer 和 Backward Layer)。在 Forward 层中, 从第 1 时刻到第  $t$  时刻, 正向计算序列数据, 得到并保存每个时刻向前隐藏层的输出; 在 Backward 层中, 沿着第  $t$  时刻到第 1 时刻反向计算序列数据, 得到并保存每个时刻向后隐藏层的输出。通过从两个方向对序列数据进行处理, 可以学习到数据中包含的历史和未来信息, 提高了预测效果的潜力。双向 LSTM 网络具体结构如图 2 所示,  $x_t$  为网络模型输入,  $h_t$  为前向传播隐藏层的网络输出,  $h'_t$  为后向传播隐藏层的网络输出,  $y_t$  表示网络模型输出。

1.2 时间序列算法 Prophet

Prophet 算法是 Facebook 开源的时序预测框架, 它的核心在于研究时序数据特征和分析周期、趋势、假日效应等时间序列特征<sup>[12-13]</sup>。趋势项允许突变点以分段、线性的方式拟合,

采用傅立叶级数建立周期模型。需要考虑节假日和特殊情况时, 通过表格形式指定节假日和相关天数。

Prophet 模型的函数表示为:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \tag{1}$$

式中:  $g(t)$  是表示趋势的变化函数, 包含逻辑回归函数和分段线性函数, 用于拟合数据中的非周期性问题。基于逻辑回归的趋势项:

$$g(t) = \frac{C}{1 + e^{-k(t-m)}} \tag{2}$$

式中:  $C$  为模型承载量,  $k$  为增长率,  $m$  为数据偏移量。伴随  $t$  的变化,  $g(t)$  趋向于上限  $C$ 。基于分段线性函数的趋势项为:

$$g(t) = (k + \alpha(t)^T \delta) + (m + \alpha(t)^T \gamma) \tag{3}$$

式中:  $k$  为增长率,  $\delta$  表示增长率的变化量,  $m$  代表数据偏移量。

在实时时间序列中, 曲线会在某个特定时间或某个潜在周期内发生变化。该模型定义了增长率  $k$  变化时对应的点, 称为变化点。在 Prophet 模型中, 需要设置变化点的位置, 而每一段的趋势和走势也是会根据变化点的情况而改变的。假设已经设置了  $S$  个变化点, 且变化点位于时间戳  $s_j$  ( $1 \leq j \leq S$ ) 上。假设存在一个向量  $\sigma \in \mathfrak{R}^S$ , 其中  $\sigma_j$  表示时间戳  $s_j$  上的增长率的变化量。若用  $k$  代替初始增长率, 则用函数  $\alpha(t) \in \{0, 1\}^S$  表示时间戳  $t$  上的增长率为  $k + \sum_{j:t > s_j} \sigma_j$ , 即时间戳  $t$  上的增长率为  $k + \alpha(t)^T \sigma$ 。其中,  $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_S)^T, \gamma_j = -s_j \sigma_j$ 。

$s(t)$  为周期项, 表示数据的季节性趋势, 通过傅里叶级数 (Fourier series) 拟合灵活的周期性效应, 表达式为:

$$s(t) = \sum_{n=1}^N \left( a_n \cos\left(\frac{2\pi nt}{p}\right) + b_n \sin\left(\frac{2\pi nt}{p}\right) \right) \tag{4}$$

式中:  $P$  为某个确定的周期,  $2n$  为希望在算法中使用的周期数目。

$h(t)$  为节假日项, 在真实环境中, 节假日或者某些大事件会对时间序列预测造成重大影响, 而这些点周期性很难判

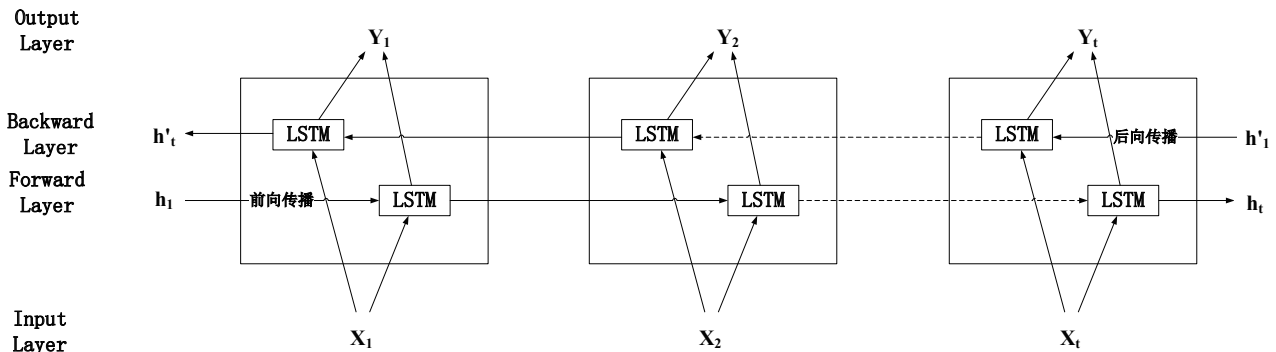


图 2 双向 LSTM 网络结构

断。所以，模型为其设置了一个虚拟变量。节假日项  $h(t)$  可以表示为：

$$h(t) = Z(t)\kappa = \sum_{i=1}^L \kappa_i 1_{(t \in D_i)} \quad (5)$$

$$Z(t) = [1_{(t \in D_1)}, \dots, 1_{(t \in D_L)}] \quad (6)$$

$$h(t) = Z(t)\kappa, \kappa \sim Normal(0, v^2) \quad (7)$$

式中： $K_i$  表示某一特定节日前后几天的影响， $D_i$  为第  $i$  个节假日的前后一段时间， $i$  为节假日， $D_i$  表示窗口期中包含的时间  $t$ 。如果时间  $t$  为虚拟变量，那么  $D_i$  值等于 1，否则为 0。 $\varepsilon(t)$  为误差，表示模型无法预测的波动，其服从正态分布。

### 2.3 相关性分析

Spearman 相关系数通常用来计算二维变量的相关性<sup>[14]</sup>。定义二维总体  $(X, Y)^T$  的观测数据为  $(x_1, y_1)^T, (x_2, y_2)^T, \dots, (x_n, y_n)^T$ 。其中，变量  $X$  和变量  $Y$  各自的样本数据为  $x_1, x_2, \dots, x_n$  和  $y_1, y_2, \dots, y_n$ ，将它们分别排序，得到两个变量各自的秩，设  $R_1, R_2, \dots, R_n$  是变量  $X$  的秩统计量  $S_1, S_2, \dots, S_n$  是变量  $Y$  的秩统计量。当  $X, Y$  的相关性比较强时，两个变量的秩统计量相关性也比较强。所以，可以通过计算变量的秩统计量的相关系数来度量变量的相关性。Spearman 相关系数的计算公式为：

$$\rho_{XY} = \frac{\sum_{i=1}^n (R_i - \bar{R})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (R_i - \bar{R})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \quad (8)$$

式中： $\bar{R} = \frac{1}{n} \sum_{i=1}^n R_i, \bar{S} = \frac{1}{n} \sum_{i=1}^n S_i$ 。

因为变量的数值相同时要求秩取值也要相同，所以将变量的数值排序后，秩取值为顺序的平均值。由秩的相关定义可以得到：

$$\bar{R} = \frac{1}{n} \sum_{i=1}^n R_i = \frac{1}{n} \sum_{i=1}^n i = \frac{n+1}{2} \quad (9)$$

同理可得， $\bar{S} = \frac{n+1}{2}$ ，经过一系列运算，得到两个变量的 Spearman 相关系数，表示为：

$$\rho_{XY} = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n d_i^2 \quad (10)$$

式中： $d_i = R_i - S_i (i = 1, 2, \dots, n)$ ，即两个变量的秩差。计算 Spearman 相关系数，也需要假设检验：

$$H_0 : \rho_{XY} = 0 \leftrightarrow H_1 : \rho_{XY} \neq 0 \quad (11)$$

同理，对给定的显著水平  $\alpha$ ，当检验值  $p < \alpha$  时，拒绝  $H_0$ ，接受  $H_1, \rho_{XY} \neq 0$ ，即变量  $X, Y$  相关，且计算的相关系数  $\rho_{XY}$  反映了两个变量的相关性强弱；而  $p \geq \alpha$ ，接受拒绝  $H_0$ ，拒绝  $H_1, X, Y$  不相关，这时没必要再计算相关系数  $\rho_{XY}$ 。

## 3 实验分析

### 3.1 数据描述及其预处理

#### 3.1.1 数据描述

本文通过查询核武器数据网站（Our World in Data <https://ourworldindata.org/nuclear-weapons>）获取到中国、法国、俄罗斯、英国、美国和以色列六个国家 1938 至 2023 年的核武器原始数据，该数据包含 5 个特征，分别为国家名称 (country)、年份 (year)、核武器储备 (stockpile)、对核武器持有不同立场的国家数量 (status)、考虑拥有核武器 (consideration)、渴望拥有核武器 (pursuit)、已经拥有核武器 (possession) 和核试验次数 (tests)。

#### 3.1.2 数据预处理

##### (1) 空缺值处理

原始数据存在空缺值和异常值等噪声数据，因此需要对其进行预处理操作。

在 1978 年某国家的核武器数量缺失，或者在 1985 年某国家的核武器数量相比上一年和下一年增加了十倍之多。对这样的数据采用均值替代法，采用同属性的已知国家的核武器数量计算并求取均值代替空缺的数据。公式如下：

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (12)$$

##### (2) 数据可视化分析

选择国家缩写名称、核武器年份、核武器储备和对核武器持有不同立场的国家数量 4 组数据，构建新的数据集。

经过对原始数据的预处理，将处理后数据可视化为折线统计图，如图 3 所示。分析发现，在 20 世纪 60 年代到 90 年代，六国核武器总数处于上升趋势，而后逐渐下降。




图 3 六国核武器总数趋势图

### 3.2 模型实现

本文以 1938 至 2003 年的六国核武器数据作为训练集，构建双向 LSTM 模型和 Prophet 模型进行拟合，最后对六个国家 2004 至 2023 年的核武器数量进行预测分析。

将 Position 与 Stockpile 数据按年份与国家进行整合。为了确定变量之间关系，了解数据中不同变量之间的相互作用，采用相关性分析技术对两组数据进行相关性分析。然后，以 1938 至 2003 年的六国核武器数据中 Position 和 Stockpile 双变量作为模型输入，构建双向 LSTM 模型进行拟合，并对六国 2004 至 2023 年的核武器数量进行预测分析。最后，选择  $R^2$ 、MAE 和 RMSE 作为预测结果的评估指标，对双向 LSTM 和 prophet 模型分别进行分析评估。具体流程如图 4 所示，具体实现步骤如下。

第一步：获取数据。获取网页数据，对数据进行可视化分析和预处理操作，将处理后数据进行保存，便于后续使用。

第二步：分析数据。计算数据相关性，将具有相关性的数据作为模型的输入。

第三步：模型构建。根据数据规模确定网络结构等参数。训练、测试双向 LSTM 模型和 Prophet 模型，计算误差，调整参数，最终输出预测结果。

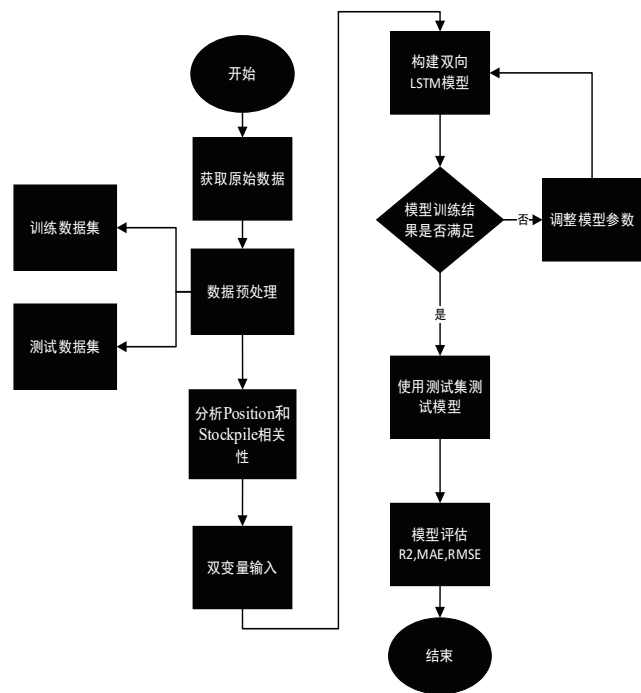


图 4 实验流程图

### 3.3 结果分析

#### 3.3.1 模型性能评估指标

模型预测效果采用  $R$  平方、均方根误差和平均绝对误差等量化指标进行评估。

(1)  $R$  平方 ( $R$ -squared,  $R^2$ )

$R^2$  是线性模型和方差分析中的常用精度度量之一，代表了模型中因变量可由自变量解释的方差百分比。 $R^2$  给出的值介于 0 到 1 之间。当  $R^2 = 0$  时，则意味着模型与平均线的结果是相同的，因此需要改进该模型；当  $R^2 = 1$  时，表示模型的拟合度非常高，这种情况只有在模型适合每个数据点并且没有出现误差时才会发生。

(2) MAE (平均绝对值误差)

为了更好地反映预测误差的情况，引入绝对误差平均值的概念。

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - g_i| \quad (13)$$

式中： $f_i$  表示预测值， $g_i$  表示真实值。

(3) RMSE (均方根误差)

RMSE 是预测值和实际真实值之间平方差异平均值的平方根，其主要衡量两者之间的偏差，对结果中的异常值较为敏感。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - g_i)^2} \quad (14)$$

#### 3.3.2 相关性结果分析

在核武器数据中，Position 数据中 Status 属性值为定类数据，Stockpile 为定量数据。考虑到两组数据是成对的有序数据，所以使用 Spearman 的秩排序相关性进行数据分析。通过绘制热度图，直观判断两组数据之间存在关系。结果显示，Stockpile 数据和 Status 属性值之间存在相关关系，相关性系数  $r_s=0.767$ 。

分析 Stockpile 与 Status 之间的关系，计算两者的相关系数，如表 1 所示，相关系数热力图如图 5 所示。

表 1 相关系数矩阵

	Stockpile	Status
Stockpile	1	0.767
Status	0.767	1

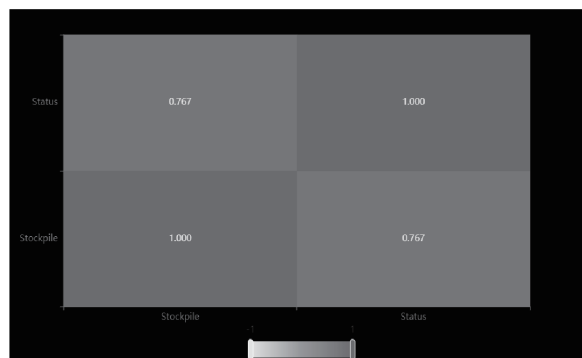



图 5 相关系数热力图

由相关性系数确定 Stockpile 与 Status 具有相关性，采用双变量输入。将 Stockpile 和 Status 双变量输入 LSTM 进行数据预测。


### 3.3.3 预测结果分析

本文应用双向 LSTM 模型和 Prophet 模型对过去 77 年的核武器数据进行训练，对预测的总体趋势进行分析，分析数据变化趋势，最终得到中国、法国、俄罗斯、英国、美国和以色列六个国家未来 20 年核武器数量的预测结果对比。


图 6 中，“Actual”表示核武器的真实值，“Prophet”表示 Prophet 模型对核武器数量的预测值，“Bi-LSTM”表示双向 LSTM 模型对核武器数量的预测值。在图 (a) 中，Prophet 预测结果部分优于双向 LSTM 预测结果，这是因为 Prophet 模型的节假日效应对该组数据适用性高。从图 (b)、(d) 和 (f) 中可以看出，两种模型对于核武器数量预测的拟合效果差异无二。图 (c) 和 (e) 中，在预测核武器数量变化方面，双向 LSTM 模型的表现明显优于 Prophet 模型，这一因素导致其最终结果也优于 Prophet 模型。




(a) 中国的核武器数据预测结果对比




(b) 法国的核武器数据预测结果对比




(c) 以色列的核武器数据预测结果对比



(d) 俄罗斯的核武器数据预测结果对比



(e) 英国的核武器数据预测结果对比



(f) 美国的核武器数据预测结果对比

图 6 双向 LSTM 和 Prophet 算法对未来 20 年国家的核武器数量预测结果对比

对于双向 LSTM 模型和 Prophet 算法，文中选取  $R^2$ 、MAPE、RMSE 作为评价指标对两者的预测结果进行评估对比，分别对各个国家的预测结果的  $R^2$ 、MAPE、RMSE 值进行计算后再取平均值，最后，对结果进行分析比较，如表 2 所示。由表 2 可知，双向 LSTM 模型相比于 Prophet 模型，MAE 和 RMSE 分别降低了 17.71% 和 16.96%， $R^2$  整体提高了 9.10%。双向 LSTM 算法比 Prophet 算法的精确度要高一些。

表 2 双向 LSTM 和 Prophet 算法的评估指标对比结果

预测评估指标	双向 LSTM 算法	Prophet 算法
$R^2$	0.863 5	0.680 4
MAE	14.418 8	177.170 0
RMSE	17.714 4	232.677 8

双向 LSTM 模型不仅对历史数据有着较好的拟合，而且预测值与真实值的差异在可接受范围内，该模型预测的精确度良好。整体来看，双向 LSTM 的预测结果优于 Prophet 的预测结果。

#### 4 结论

双向 LSTM 模型通过将时间戳作为输入序列的一部分来学习序列之间的模式和关联。前向 LSTM 和后向 LSTM 分别对输入序列进行处理，之后将两个 LSTM 的输出拼接，进而得到双向 LSTM 最终的输出结果。对于给定历史数据中核武器的立场 (Position) 和核武器库存 (Stockpile)，双向 LSTM 从两个方向分别处理输入数据，捕获数据较长距离的依赖关系，最后预测之后 20 年的数据。相比于 Prophet 模型，双向 LSTM 本身的结构设计更易于处理无周期性、非线性的数据。同时，由于双向 LSTM 高效的学习能力，它在复杂的序列数据预测任务中表现优异。实验结果显示，双向 LSTM 模型的误差低于 Prophet 模型。这表明双向 LSTM 模型本身的门控机制、优良的结构对核武器数量的历史数据的有效拟合，使其更接近真实情况，从而显著提高了模型的预测精度和结果。因此，将双向 LSTM 应用于核武器数量预测分析是一种较为有效的研究方法，可以借此分析世界局势和评估各国军事实力。

#### 参考文献:

[1] 李钰, 李云龙. 核弹爆炸的威力 [J]. 青少年科技博览, 2022(10): 35-37.  
 [2] SUN X. The development of nuclear weapons in china [EB/OL]. (2016-01-01)[2024-02-22]. <https://www.jstor.org/stable/>

resrep26903.8.

[3] 赵继珂. 美国对以色列发展核武器的评估和对策 (1958—1974 年) [D]. 沈阳: 东北师范大学, 2011.  
 [4] KRISTENSEN H M, KORDA M. Tactical nuclear weapons, 2019 [J]. Bulletin of the atomic scientists, 2019, 75(5): 252-261.  
 [5] KRISTENSEN H M, KORDA M. United States nuclear weapons, 2021 [J]. Bulletin of the atomic scientists, 2021, 77(1): 43-63.  
 [6] KRISTENSEN H M, KORDA M. Russian nuclear weapons, 2022 [J]. Bulletin of the atomic scientists, 2022, 78(2): 98-121.  
 [7] KRISTENSEN H M, KORDA M, JOHNS E. French nuclear weapons, 2023 [J]. Bulletin of the atomic scientists, 2023, 79(4): 272-281.  
 [8] KRISTENSEN H M, KORDA M, REYNOLDS E. Chinese nuclear weapons, 2023 [J]. Bulletin of the atomic scientists, 2023, 79(2): 108-133.  
 [9] KRISTENSEN H M, KORDA M. United Kingdom nuclear weapons, 2021 [J]. Bulletin of the atomic scientists, 2021, 77(3): 153-158.  
 [10] KRISTENSEN H M, KORDA M. Israeli nuclear weapons, 2021 [J]. Bulletin of the atomic scientists, 2022, 78(1): 38-50.  
 [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735-1780.  
 [12] 马勋政, 张吴波. Prophet-LSTM 混合模型对卷烟投放的预测 [J]. 牡丹江师范学院学报 (自然科学版), 2022(4): 29-34.  
 [13] 张骏, 周磊, 王文梁, 等. 基于 Prophet 模型的空气污染物浓度预测方法 [J]. 中国环境监测, 2022, 38(6): 59-68.  
 [14] 徐维超. 相关系数研究综述 [J]. 广东工业大学学报, 2012, 29(3): 12-17.

#### 【作者简介】

王彩玲 (1984—), 女, 宁夏吴忠人, 博士, 副教授, 研究方向: 遥感图像处理、人工智能。

张智栋 (2000—), 男, 陕西渭南人, 硕士, 研究方向: 计算机视觉与深度学习应用。

(收稿日期: 2024-03-19)