

基于 PCA-GWO-GRU 的锂离子电池剩余使用寿命预测^①

李钰, 卓晓军, 刘洋, 李重洋

(长沙矿冶研究院有限责任公司, 湖南 长沙 410012)

摘要: 为了提高 GRU 神经网络模型预测锂离子电池剩余使用寿命时的准确性, 提出基于 PCA-GWO 优化的 GRU 模型, 并应用于锂离子电池剩余寿命预测。结果表明, 与传统 GRU 模型相比, 经 PCA-GWO 算法优化的 GRU 模型具有更高的预测精度。预测起始点为原始数据 90% 时, 预测精度达到最大, 对应的均方根误差 RMSE 为 0.0049、平均绝对误差 MAE 为 0.0036、决定系数 R^2 为 0.9863。

关键词: 锂离子电池; 剩余使用寿命预测; GRU; 灰狼算法; 主成分分析

中图分类号: TM912

文献标识码: A

doi: 10.3969/j.issn.0253-6099.2024.04.018

文章编号: 0253-6099(2024)04-0095-05

Prediction of Remaining Useful Life of Lithium-Ion Batteries Based on PCA-GWO-GRU

LI Yu, ZHUO Xiaojun, LIU Yang, LI Chongyang

(Changsha Research Institute of Mining and Metallurgy Co., Ltd., Changsha 410012, Hunan, China)

Abstract: In order to improve the accuracy of the GRU neural network model in predicting the remaining useful life (RUL) of lithium-ion batteries, the GRU model was optimized based on PCA-GWO and then applied in the prediction. The results show that compared with the traditional GRU model, the PCA-GWO-GRU model presents higher prediction accuracy. When the starting point of the prediction is 90% of the original data, the prediction accuracy can reach the highest, with the corresponding RMSE of 0.0049, MAE of 0.0036, and R^2 of 0.9863.

Key words: lithium-ion battery; remaining useful life (RUL) prediction; GRU; gray wolf optimizer (GWO); principal component analysis (PCA)

锂离子电池具有快速充电、长寿命、高能量密度和无记忆效应等特点, 在各领域大量使用。但是, 随着电池充放电次数和工作时长增加, 电池容量逐渐下降。为了保障电池安全性能, 对电池剩余使用寿命 (remaining useful life, RUL) 进行预测十分关键。目前使用的 RUL 预测方法主要分为经验退化模型预测方法、浅层方法、深度学习的方法以及融合预测方法^[1]。深度学习的方法中, 主要采用循环神经网络 (recurrent neural network, RNN) 和卷积神经网络 (convolutional neural networks, CNN) 进行学习及预测^[2-5], 但 RNN 成本高且存在长期依赖问题, CNN 在时序特征处理受限。将一些优化算法引入神经网络对电池剩余使用寿命的预测将会提升预测效果。数据驱动方法直接利用监测数据建模, 具有便捷性及普适性, 将其应用于深度

学习方法中, 所建模型适应性更强。本文提出基于 GRU (gate recurrent unit) 神经网络模型的 RUL 预测方法, 利用灰狼算法 (grey wolf optimizer, GWO) 对神经网络进行全局优化, 提高预测效果和稳定性。此外, 还采用主成分分析方法 (principal component analysis, PCA) 对原始数据进行处理, 有效利用输入信息并提高预测精度, 验证数据驱动预测方法的优越性。

1 基于数据驱动的电池剩余使用寿命预测

锂离子电池剩余使用寿命预测涉及利用过往退化信息完善模型, 通过分析过往数据预测之后的退化趋势, 准确估算锂离子电池 RUL。

长短期记忆网络 (long short-term memory, LSTM) 模型在长序列模型预测中应用较为广泛。在 LSTM 的

① 收稿日期: 2024-05-25

基金项目: 湖南省科技重大专项 (2023GK1070); 湖南省科技创新领军人才 (2021RC4046)

作者简介: 李钰 (2000—), 男, 江西宜春人, 硕士研究生, 主要研究方向为锂离子电池拆解及寿命研究。E-mail: 1102597939@qq.com

通信作者: 卓晓军 (1978—), 男, 四川自贡人, 博士, 正高级工程师, 主要研究方向为深海采矿与绿色冶金。E-mail: zhuoxj@minmetals.com

刘洋 (1983—), 男, 湖南岳阳人, 博士, 高级工程师, 主要研究方向为选冶智能化。E-mail: liuyang0730@qq.com

环状结构单元里,遗忘门、输入门以及输出门担当着极其关键的功能,它们协作处理过去时刻的隐含层状态和现在时刻的输入信息。这些结构中,控制信息流转的调节器核心部分由 sigmoid 函数和乘法操作的结合体组成。该算法初始阶段利用 sigmoid 函数将输入数据缩放到 0~1 范围内,即归一化处理,接着利用乘法操作来决定输入信息的筛选与忽略比例,其中数值为 0 代表完全忽略信息,数值为 1 代表完全保留信息。信息筛选机制包括遗忘门、输入门和输出门的相互作用,能有效筛选并保留关键信息,同时忽视无关信息,达到长序列学习的目的。

基于 LSTM 模型,文献[6]提出了 GRU 架构。GRU 与 LSTM 的核心区别在于其内部循环单元体的架构。LSTM 是借助遗忘门、输入门和输出门三种门控机制,对输入信息及前一时刻隐含层信息进行选择性保留或遗忘;GRU 简化了架构,仅利用更新门和重置门两个调控机制便实现了与 LSTM 相近的性能^[7]。这种简化方法不仅加快了计算效率,节省了存储资源,也让模型的训练过程更易操作。因此,GRU 在处理时序数据时表现出更高的效率。GRU 循环体单元的内部结构^[8]见图 1,图中 \tilde{h}_t 为当前时刻隐含层的激活状态, φ 为 tanh 激活函数, h_t 为当前时刻的隐含层状态, h_{t-1} 为上一时刻的隐含层状态, r_t 为重置门, z_t 为更新门。通过图 1 可以直观理解 GRU 模型的工作原理。




图 1 GRU 循环体单元内部结构

GRU 循环单元由重置门和更新门构成。它们输入的信息是当前输入和前一层隐状态,随后由权重矩阵乘法和 sigmoid 函数处理,计算它们的值。在这里,更新门的工作是调节前一时刻信息流入当前时刻的程度,更新门的值越趋近 0,其对前一时刻信息遗忘越彻底。更新门的计算公式为:

$$I_z = w_z x_t + u_z h_{t-1} \quad (1)$$

$$z_t = \sigma(I_z) \quad (2)$$

式中: w_z 、 u_z 均为权重; x_t 为当前时刻的输入; σ 为 sigmoid 函数; I_z 为更新门激活函数的输入。

在 GRU 中,重置门决定了上一时刻信息被忽略的

程度,其值越趋近 1,对前一时刻的信息保存越完整。对应的数学公式为:

$$I_r = w_r x_t + u_r h_{t-1} \quad (3)$$

$$r_t = \sigma(I_r) \quad (4)$$

式中: w_r 、 u_r 均为权重; I_r 为重置门激活函数的输入。

更新之后,通过重置门机制对前一时刻隐藏状态产生影响。采用重置门机制对前一时刻隐含层状态进行调整,结合该状态与当前时刻的输入数据进行融合。接着,启用适当的系数矩阵,执行合成信息的累计操作。经过这个阶段,便能收获一个全新的向量。为了获取即时状态下隐藏层的激活特征,所述向量需经过 tanh 激活函数加工,从而获得期望的输出。计算公式为:

$$I_{\tilde{h}} = w x_t + u(r_t \odot h_{t-1}) \quad (5)$$

$$\tilde{h}_t = \varphi(I_{\tilde{h}}) \quad (6)$$

式中: w 、 u 均为权重; \odot 为矩阵的 Hadamard 积; $I_{\tilde{h}}$ 为 tanh 激活函数的输入。

处理即时隐含层状态时,更新门机制被巧妙地运用。更新不仅影响前一时刻的隐含层状况,亦同时触及即时时刻隐含层的激活状况。处理两种情况后,便收获了各自相应的成果。随后,对这两个结果进行合并计算,得出当前时刻的隐含层状态。数学表达式为:

$$h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \quad (7)$$

在 LSTM 和 GRU 的架构里,环形结构单元扮演了至关重要的角色,它主要承担对传入信息进行深度挖掘与加工的任务。经过这一流程,循环单元能测算出即时时刻的隐含层输出 h_t 。一旦获得了隐含层输出,便可将其传递至神经网络的输出层。在解码阶段,透过繁复的算术操作链,能获取神经网络的最终结果。输出层计算公式为:

$$I_y = w_y h_t \quad (8)$$

$$y = \sigma(I_y) \quad (9)$$

式中: w_y 为权重; y 为神经网络的输出; I_y 为激活函数的输入。

传统 GRU 模型运用梯度下降策略优化其权重,由式(1)~(9)可以看出, w_z 、 u_z 、 w_r 、 u_r 、 w 、 u 、 w_y 都是 GRU 模型需要训练的参数,将 t 时刻 GRU 的损失函数 E_t 定义为:

$$E_t = \frac{1}{2} (y_t - Y_t)^2 \quad (10)$$

式中: Y_t 为真实值; y_t 为预测值。则整个预测过程中的预测误差 E 为:

$$E = \sum_{t=1}^T E_t \quad (11)$$

GRU 神经网络预测模型经过以上训练过程,按照

所得最优权重进行预测,可较理想地实现预测功能,得到较好的预测效果。

2 GRU 算法寻优与机制优化

2.1 灰狼算法

为提升 GRU 模型的预测准确性,通过深入对比相关文献[7-8],发现传统智能优化算法,如粒子群算法、遗传算法、进化策略等,在实际应用中面临搜索效率低下、对初始种群敏感以及难以有效处理长期依赖关系等问题。为了充分利用 GRU 模型在处理长序列数据时的高效性,并进一步提高模型在求解问题时的精确度和收敛速度,选择了灰狼优化(grey wolf optimizer, GWO)算法作为优化工具。

自然界中的灰狼是群居动物,它们的社会等级区分严格,其等级制度如图 2 所示。最上层的 α 级别最高,它主要负责分配食物、决策狩猎等重要的事务,其他狼要听从它的安排;第二层是 β 狼,它可以协助 α 狼并承担沟通的作用,它还可以在 α 狼不在时顶替 α 狼。第三层是 δ 狼,它的工作是调差、岗哨及看护等,且它需要完全服从 α 狼和 β 狼。第四层是 ω 狼,它的主要工作是维持种群的关系协调,其适应度很低。




图 2 灰狼的社会等级制度

2.2 主成分分析法

主成分分析(principal component analysis, PCA)是一种主要应用于预测方向的预处理技术^[9]。它的工作原理是将多个原始变量转换为几个可以代表原始数据主要信息的关键成分,其中第一个主成分一般包含最多的数据信息。实际情况下,它的作用一般是降低数据维度以及消除冗余,将高维数据转换为几个关键主成分的低维数据。

锂离子电池的容量变化曲线存在许多噪声,这些噪声的存在会使模型在预测时存在干扰,这对锂离子电池 RUL 预测会产生不利影响。为了降低噪声所产生的影响,同时使计算复杂程度降低,本文选择主成分分析方法对原始数据进行处理。主成分分析法选取数据时,对原始数据进行标准化处理:

$$\mathbf{Z}_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j} \quad (i = 1, 2, \dots, p) \quad (12)$$

式中: x_{ij} 为第 i 个评价对象的第 j 个指标的取值; \bar{x}_j 为均值; σ_j 为标准差; \mathbf{Z}_{ij} 为标准化数据矩阵。

计算特征向量 \mathbf{R} :

$$\mathbf{R} = [r_{ij}]_p, \quad |\lambda_i \mathbf{I} - \mathbf{R}| = 0 \quad (i = 1, 2, \dots, p) \quad (13)$$

式中: r_{ij} 为标准化数据 Z_i 和 Z_j 的相关系数; \mathbf{I} 为单位矩阵。同时可得到 p 个特征值 $\lambda_i (i = 1, 2, \dots, p)$, 将其按照从大到小的顺序排列为: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, 可分别求出对应的特征向量 \mathbf{e}_j 。

第 k 个主成分 Y_k 的方差贡献率 a_k 为:

$$a_k = \frac{\lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (k = 1, 2, \dots, p) \quad (14)$$

则 Y_1, Y_2, \dots, Y_m 的累计方差贡献率 a 为:

$$a = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^p \lambda_i} \quad (15)$$

进行主成分分析的主要作用是减少变量个数,所以分析之后的个数 m 小于样本数量 p 。 m 的范围一般不会使累计贡献率小于 85%,只有这样才能确保损失的信息少,同时达到减少变量个数的目的。

然后,确定主成分,计算各个主成分的得分值 G :

$$G = \mathbf{e}_i^T \mathbf{X}_j \quad (i = 1, 2, \dots, m; j = 1, 2, \dots, p) \quad (16)$$

数据经过 PCA 处理后便可输入到模型中。

2.3 PCA-GWO-GRU 预测模型整体框架

PCA-GWO-GRU 预测模型步骤如下:

- 1) 对原始数据进行预处理和归一化处理。
- 2) 通过 PCA 分析归一化处理后的数据,累计贡献率不小于 85%时作为 GRU 模型的输入。
- 3) 采用 GWO 对 GRU 模型进行优化,定义 GRU 模型的学习率、隐藏节点个数、正则化参数作为 GWO 的初始化参数。
- 4) 将 GWO 算法种群初始化。根据灰狼的社会行为进行迭代优化,更新灰狼种群,即 GRU 模型的参数。
- 5) 确定适应度值函数。将灰狼个体中的初始参数作为 GRU 模型的初始值,通过神经网络训练得到输出值 o_k 和希望输出值 y_k 。其平均误差作为适应度值函数 F 。

$$F = \frac{1}{A} \sum_{s=1}^A \sqrt{\sum_{k=1}^n (y_k - o_k)^2} \quad (17)$$

- 6) 依据式(17)确定第一代灰狼适应度值,在狼种群中选取 α, β 和 δ 。

- 7) 更新 GWO 中的参数。

8) 检查迭代次数是否达到设定值。如果没有,则返回第5步;如果完成,则获取 GWO 最优初始参数。

9) 最终对数据进行预测。

3 实验

3.1 数据集介绍

在湖南某新能源科技公司进行汽车退役电池充放电循环实验,获得本文训练集和测试集数据。实验使用比克 2.4 Ah 电池,实验过程中,电池以电流 1.2 A 恒流恒压充电至 4.2 V,截止电流 0.048 A,静置 30 min,再以电流 2.4 A 恒流放电至 2.75 V,再静置 30 min。重复以上步骤,每 10 次循环测试后记录电池各项信息。

在所收集的电池数据中,训练集数据共 110 个,测试集数据共 15 个。实验的输入特征为电池容量和循环次数。此外,为了探索不同起点下模型的性能,定义预测起点 P_{RUL} 为:

$$P_{RUL} = \frac{N_{start}}{N_{EOL}} \times 100\% \quad (18)$$

式中: N_{EOL} 为电池的完整周期寿命; N_{start} 为电池从健康状态到预测开始的位置所经历的循环次数。

为体现方案对比的公平性,GRU 模型结构部分参数设置如下:时间步长为 1,隐含层大小为 256。

3.2 方法对比实验验证

为了检验本文所提出方法的有效性,设计了对比实验:利用不同神经网络或算法将训练集的所有数据进行迭代处理,同时将测试集中拟合效果较好的预测段作为实验结果的验证集。本次对比试验采用了 LSTM、GRU、VMD-PSO-GRU、PCA-GWO-GRU 共 4 种模型。以均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 R^2 为评价指标,用于评价模型预测的准确性:

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (20)$$

$$R^2 = 1 - \frac{R_{SS}}{R_{total}} \quad (21)$$

式中: y_i 和 \hat{y}_i 分别为电池放电容量的真实值和预测值; R_{SS} 为残差平方和; R_{total} 为总平方和; N 为样本数量。 R^2 越接近 1,说明模型能很好地解释因变量的变化, R^2 越接近 0,说明模型对因变量的变化没有解释能力。

实验过程中发现,大部分电池都经历了 600 次左右的充放电循环,且电池容量在总数据量 80% 之后容量参数发生较大变化。为了对比验证不同方法的预测

效果,选择原始数据量的 80% 作为预测起点,开展进一步的实验,对测试集中效果较好的两个电池 b1、b2 进行展示,图 3 为不同预测方法对电池 b1 的预测效果,表 1 为不同测试方法的预测评价指标。

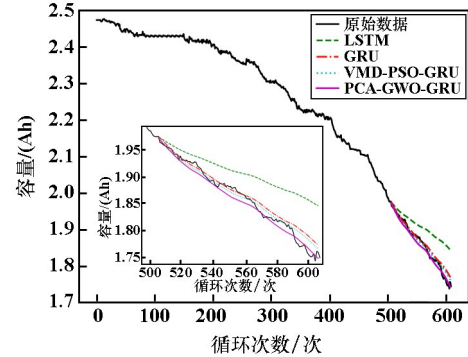


图 3 b1 电池预测效果对比

表 1 不同预测方法的预测评价指标

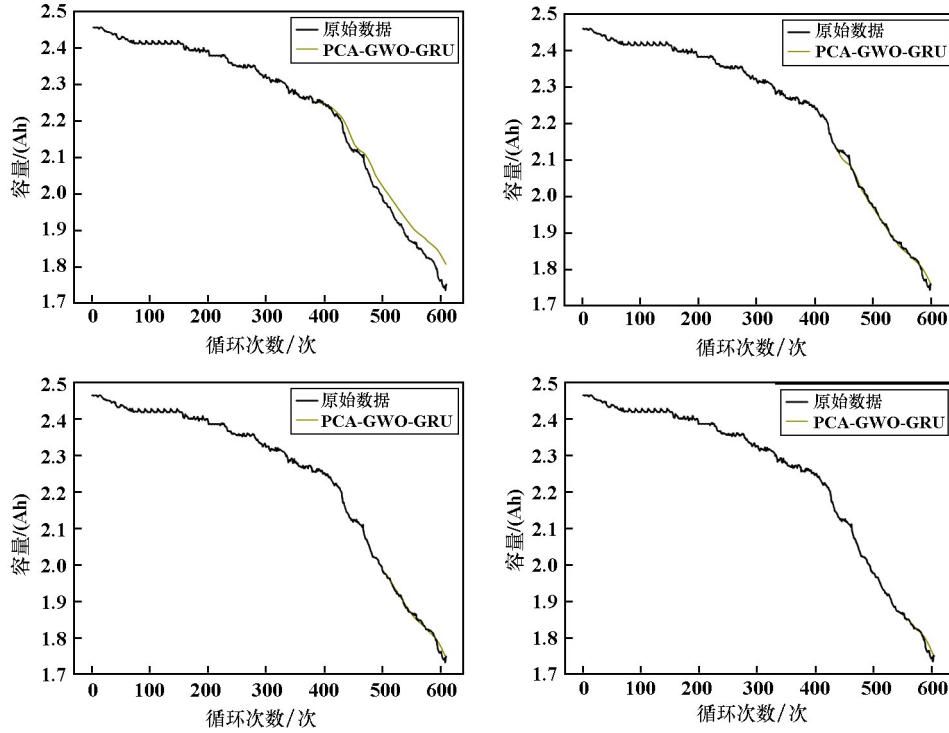
电池名称	预测方法	RMSE	MAE	R^2
b1	LSTM	0.028 9	0.027 1	0.863 3
	GRU	0.021 3	0.019 4	0.926 1
	VMD-PSO-GRU	0.020 2	0.019 1	0.933 4
	PCA-GWO-GRU	0.015 1	0.014 3	0.962 9
b2	LSTM	0.032 1	0.030 3	0.835 4
	GRU	0.020 7	0.018 9	0.931 2
	VMD-PSO-GRU	0.018 4	0.017 5	0.945 3
	PCA-GWO-GRU	0.012 1	0.011 4	0.976 4

从表 1 可以看出,4 种方法中,PCA-GWO-GRU 预测性能最佳,LSTM 预测效果最差。这可能是 PCA 技术将数据中一些噪声或冗余信息进行了消除,且 GWO 优化算法的自适应调整机制对模型预测效果起到了优化作用。表明主成分分析以及 GWO 算法对 GRU 模型具有较好的增强效果,使得优化模型预测电池剩余使用寿命精确性更高。

3.3 时间消融对比实验验证

继续使用上述数据以及训练模式,分别采用预测起点 60%、70%、80%、90% 的历史容量数据预测剩余使用寿命期间的容量走向。b2 电池不同预测起点的预测结果见图 4。结果表明,b2 电池不同时间段预测起点的预测结果误差均较小。通过观察发现,随着预测起点后移,预测曲线与原始曲线之间的间隔越来越小,说明随着预测起点后移,其预测误差值更低,预测效果更好。

b2 电池不同预测起点的预测评价指标如表 2 所示。预测起点 90% 时预测效果最好,相应的 RMSE 为 0.004 9、MAE 为 0.003 6、 R^2 为 0.986 3。同时发现,随着预测起点后移,该神经网络的预测性能越理想,相对误差更小。且其整体性能都在合理范围内,充分展现该神经网络预测模型的优越性能。



(a) 60%; (b) 70%; (c) 80%; (d) 90%

图 4 b2 电池不同预测起点的预测曲线

表 2 不同预测起点在测试集电池 b2 上的性能展示

预测起点/%	RMSE	MAE	R ²
60	0.027 4	0.021 8	0.974 7
70	0.020 6	0.018 7	0.974 8
80	0.012 1	0.011 4	0.976 4
90	0.004 9	0.003 6	0.986 3

4 结 论

建立了基于 PCA 和 GWO 算法优化的 GRU 网络预测模型,并应用其预测锂离子电池剩余使用寿命。该模型能高效掌握锂离子电池容量的衰减规律,与基于 LSTM、GRU 以及 VMD-PSO-GRU 的预测模型相比,该预测模型展现了卓越的预测性能,其预测均方根误差 RMSE 为 0.012 1、平均绝对误差 MAE 为 0.011 4、决定系数 R² 为 0.976 4;时间消融实验结果表明,随着时间起点推移,其预测效果更好,预测起点 90%时预测效果最好,对应的 RMSE 为 0.004 9、MAE 为 0.003 6、R² 为 0.986 3。

参考文献:

[1] 王志福,杨忠义,罗崴,等. 基于数据驱动的锂离子动力电池剩余

使用寿命预测方法综述[J]. 科学技术与工程, 2023, 23(15): 6279-6289.

[2] 皇甫海文,韩艾呈. 锂离子电池等效模型建立与参数辨识方法研究[J]. 电气开关, 2020, 58(3): 37-41.

[3] 向铭,何怡刚,张慧. 基于改进集成经验模态分解和高斯过程回归的锂离子电池剩余容量及寿命预测方法[J]. 电测与仪表, 2023, 60(9): 27-33.

[4] 梁海峰,袁芑,高亚静. 基于 CNN-Bi-LSTM 网络的锂离子电池剩余使用寿命预测[J]. 电力自动化设备, 2021, 41(10): 213-219.

[5] REN L, DONG J, WANG X, et al. A data-driven auto-CNN-LSTM prediction model for lithium-ion battery remaining useful life [J]. IEEE Transactions on Industrial Informatics, 2020, 17(5): 3478-3487.

[6] 姚程文,杨苹,刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.

[7] MIRJALILI S. How effective is the Grey Wolf optimizer in training multi-layer perceptrons[J]. Applied Intelligence, 2015, 43(1): 150-161.

[8] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.

[9] 张建文,杨晨,冉懿,等. 基于 PCA-GPQR 的电网负荷短期概率预测[J]. 电力系统及其自动化学报, 2020, 32(5): 24-29.

引用本文: 李钰,卓晓军,刘洋,等. 基于 PCA-GWO-GRU 的锂离子电池剩余使用寿命预测[J]. 矿冶工程, 2024, 44(4): 95-99.