

基于卷积神经网络的呼吸变化趋势预测模型



李钰雯^{1,2}, 田悦芃¹, 戚晓玲², 甘俊杰², 黄栋¹, 张志民³

1. 东南大学, 江苏 南京 210096

2. 航空工业航宇救生装备有限公司 航空防护救生技术航空科技重点实验室, 湖北 襄阳 441003

3. 中国药科大学, 江苏 南京 211198

摘要:在航空航天领域,飞行员的生理健康与飞行安全紧密相连,其中,呼吸系统的健康状态尤为重要,而呼吸气面罩的舒适佩戴体验与高效的氧气利用率,则是保障呼吸健康进而维护飞行安全的两个至关重要的因素。传统的航空氧气面罩主要通过内置的传感器完成滞后的呼吸气阀调节,使用者往往会感受到面罩呼吸阻力大,佩戴舒适性欠佳。为了提升飞行员的操作体验和安全性,本文建立呼吸变化趋势预测模型,旨在为呼吸防护中的呼吸供氧主动调节提供新的解决方案。本文提出一种基于卷积神经网络(CNN)算法的预测模型,即根据入口压和位移传感器采集的相应呼吸数据对15s后的出口压数据进行预测,即预测呼吸变化趋势,进而实现呼吸的主动供氧与调节。研究表明,本文提出的呼吸变化趋势预测模型精度为92.422%。此模型可以提高氧气面罩的舒适性及氧气利用率,且对呼吸防护方面具有重要意义。

关键词:呼吸预测;深度学习;卷积神经网络;主动调节

中图分类号: TP18

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2025.01.004

应对高空的气压环境是人类飞行活动的重要挑战之一^[1-3]。强烈的气压变化会严重影响人体的呼吸生理反应,在变化持续时间长、变化速度过快时,其影响更加剧烈^[4-7]。一旦超过飞行员的耐受极限,就可能出现飞机失能失控。高空气压环境因素的改变能引起人体一系列的呼吸生理反应,其中强烈者或作用时间过长或变化过快者将超过飞行员的耐受极限,导致飞行失能影响飞行操控。特别是气压环境的改变致使人体呼吸产生病理变化,甚至是器质性损害。为了有效保障飞行员的生命健康,确保飞行安全,呼吸防护装备至关重要,也是飞行员飞行活动性命悠关的生命保障系统^[8]。航空供氧面罩能够在高空气压环境下为飞行员进行稳定供氧以及排出二氧化碳,极大地保证了飞行安全。而经过不断的技术发展,呼吸防护监测除了需要大量的地面模拟试验数据外,迫切需要对飞行员实际飞行时的呼吸生理反应进行记录并分析^[9]。为了保障飞行员战斗力的恢复与维持,精准监测呼吸生理情况,开发有效的智

能感知系统和呼吸监控系统已刻不容缓^[10-12]。

2008年以来,F-22飞机出现了几起不明原因的缺氧事故,促使美国军方开始探索安装在氧气面罩上测量吸入气体氧气体积分数的方法,以便为飞行员提供关于供氧状态的实时信息,从而准确预测将来飞行中出现的缺氧事件^[13]。研究难点在于需要在气压环境波动、极端温度、高氧气体积分数和湿度等极端的环境中获得准确的飞行中面罩内的氧气体积分数相关数据,对检测技术要求极高。目前,美国Orbital Research公司已开发出带有嵌入式生理传感器组件的面罩,利用传感器记录面罩内的压力、流量、氧气和二氧化碳分压,但测量有效性和精度仍需通过地面和飞行测试进行验证。国内方面对航空供氧面罩内的氧气体积分数监测研究尚处于起步阶段。

当前的航空氧气面罩一般只能完成滞后的呼吸气阻力调节,使用者往往会感到面罩呼吸气阻较大。此外,对于呼吸阻力的研究发现,随着呼吸阻力增加,佩戴者的每分钟肺

收稿日期: 2024-04-09; 退修日期: 2024-08-26; 录用日期: 2024-11-04

基金项目: 航空科学基金(20200029069001)

引用格式: Li Yuwen, Tian Yuepeng, Qi Xiaoling, et al. Prediction model of respiratory trend based on convolutional neural networks[J]. Aeronautical Science & Technology, 2025, 36(01): 33-38. 李钰雯, 田悦芃, 戚晓玲, 等. 基于卷积神经网络的呼吸变化趋势预测模型[J]. 航空科学技术, 2025, 36(01): 33-38.

通气量降低,机体获取氧气减少,最终导致代谢水平降低。同时,对于正压氧气呼吸面罩而言,氧气的利用率也同样有待提高。因此,如果能够通过传感器数据完成对于后续呼吸过程的预测,形成主动的呼吸调节,对于上述问题的改善具有关键作用。

近几年,随着深度学习技术的快速发展,基于它在特征提取以及函数模拟等方面的优势,各行各业都在不断地尝试将人工智能(AI)技术与本领域进行融合,解决各种各样的实际问题。深度学习对于各种生理信号的处理效果都要优于传统算法,所以自然也是呼吸生理信号预测的重要方法之一。卷积神经网络(CNN)是一类包含卷积运算且具有深度结构的前馈神经网络,是深度学习的代表算法之一^[14]。它使用多个卷积核对数据进行不断地卷积操作,提取数据中的深层特征^[15],尤其是CNN模型在处理时序和多维数据方面表现出色,能够有效提取特征和捕捉复杂模式。CNN具有较好的泛化能力和训练效率。

因此,本文提出了一种基于CNN的呼吸变化趋势预测模型。该模型输入入口压力和位移数据,输出和通气流量呈正相关的出口压力数据。首先对原始数据进行格式转换和批标准化。然后经过多层卷积层和激活函数层,提取深层特征的同时,使用随机失活层抑制过拟合。最后经过全连接层整合深层特征,再通过回归层输出预测结果。该模型在减少计算量、加快收敛速度的同时,还具有更强的泛化能力。

1 理论基础

1.1 呼吸器原理

呼吸器的模型可以简化为外界空气通过一个阀门,连接到面罩管路,再与人体呼吸道连通的情况。人体呼吸过程包含两个阶段:吸气时,上呼吸道压力小于呼吸机的通气压力,气体由外部空气流向面罩通路,阀门开度变大;呼气时,上呼吸道压力大于呼吸机的通气压力,气体由面罩通路流向外部空气,阀门开度变小,如图1所示。

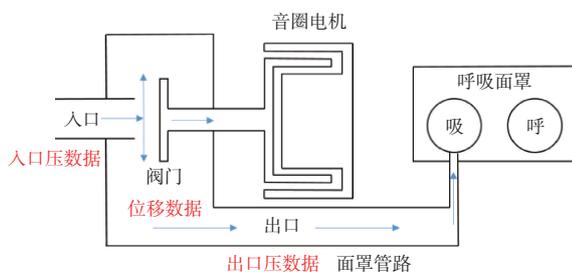


图1 呼吸器示意图

Fig.1 Schematic diagram of the breathing apparatus

与本文相关的呼吸数据有三个:(1)与外部空气端相连接的入口压力数据;(2)与外部空气端相连接的入口处阀门位移数据;(3)与面罩端相连接的面罩管路出口压力数据。

在正常工作时,呼吸器会提供持续的正气道压力来保持航天员在高空中呼吸通气通畅。此时根据物理学原理可知,流体在某处的压强与流速具有对应关系。事实上,呼吸面罩的出口压力数据和通气流量呈正相关,因而获取准确的出口压力数据至关重要。在此基础上,只需预测出口压力值,就相当于对人体呼吸变化趋势进行了预测。

1.2 CNN

常见的CNN主要包含卷积层、激活函数、池化层、随机失活层、全连接层、输出层等^[14]。

(1)卷积层

卷积层是卷积神经网络中的核心层,也是最关键的一层,这一层的主要工作就是进行卷积操作。

卷积操作实际上就是让一个指定尺寸的卷积核与输入数据的当前部分进行逐项相乘相加,最后加入偏置项,得到卷积图上的一个值。该卷积核以指定步长遍历全部原始数据,就能够得到一张特征图。但是经过卷积运算,特征图的长宽往往会比原始数据小,为了使特征图和原始数据保持相同的维度,可以使用边缘填充(padding)操作在原始数据的四周全部填充0。

每个卷积核对输入数据进行卷积能够生成一张特征图,多个卷积核就能够得到多张特征图的堆叠。一般来说靠近输入层的卷积层提取浅层特征,远离输入层的卷积层能够提取深层特征。

(2)激活函数

激活函数一般是一个非线性函数^[14],它的加入为神经网络引入了非线性因素,使得神经网络能够逼近任何非线性函数。常见的激活函数有ReLU、tanh、sigmoid等。本文中主要使用了ReLU激活函数, $y=\max(0, x)$,如图2所示。ReLU函数在 $x>0$ 时 $y=x$,在 $x=0$ 时 $y=0$ 。该函数的优势在于形式简单,求梯度非常便捷,并且收敛快速,因而在各类深度学习算法中被广泛应用。

(3)随机失活层

随机失活层是深度学习中防止过拟合的常用操作,它的作用是在每个批次(Batch)训练时随机令某一指定百分比数量的神经元失能,或断开和前后层的连接,不能参与当前轮次的训练^[15],如图3所示。

这样的操作让神经网络不过度依赖某几个或少数特征,能够在很大程度上抑制过拟合,增强模型的泛化能力。

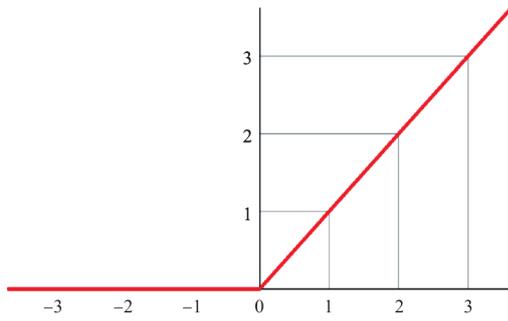


图2 ReLU函数示意图

Fig.2 Schematic diagram of the ReLU function

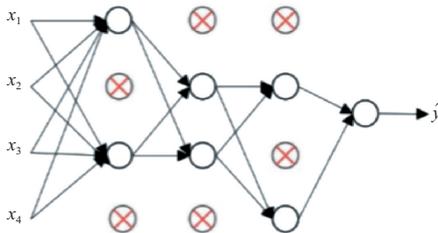


图3 Dropout层示意图

Fig.3 Schematic diagram of Dropout layer

(4)全连接层

全连接层由指定数目的神经元组成,广泛用在多个卷积层提取深度特征之后,对其进行整合。数据输入时,需要前面多个卷积层得到的多维数据展开成一维;而后对该一维数据与全连接层中的每个神经元的权重相乘,加入偏置项,得到全连接层的输出。该层的主要作用是对前面卷积层提取出的大量特征进行整合,以更好地完成分类或回归任务。

2 基于CNN的呼吸趋势预测模型

本文介绍了一种基于CNN的呼吸趋势预测模型。该模型的主体部分由卷积层构成,算法主体结构、各层的说明、可学习参数量、输出维度见表1。

首先将入口压呼吸数据与位移数据进行训练集、测试集的划分,选取训练集和测试集的比例为7:3,并将原始数据格式进行转换,使数据能够输入卷积层进行训练。批标准化将转换格式后的数据进行统一的标准化操作,具体而言,则是对每一个批次的的数据归一为标准正态分布,即零均值,单位方差的状态,这样更有利于网络的训练。

此处的4层卷积操作中也使用了扩张卷积操作。也就是在传统卷积的卷积核的格点之间插入零值,在不增加计算量的情况下加大了卷积核的覆盖面积,因而扩张卷积具有更大的感受野,这样卷积层得到的特征蕴含更全局、更深

层的特征。

随机失活层的输入参数选定为0.5,即每轮训练随机选定50%的神经元失能,能够有效抑制网络训练过拟合。

该模型以均方差(MSE)作为模型损失函数,MSE被定义为

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (1)$$

式中, N 为样本数; y_i 为实际值; \hat{y}_i 为模型预测值。此外,模型还用到了绝对平均误差(MAE)及均方根误差(RMSE)来对模型的性能进行评估,这两个指标被定义为

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3)$$

该模型用决定系数(R^2)值作为模型性能的评估指标。 R^2 反应了 y 的波动有多少百分比能被 x 的波动所描述,该值介于0和1之间,且越接近1,模型的解释力越强。 R^2 值被定义为

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

式中, \bar{y} 代表真实值的平均值。

表1 CNN模型结构

Table 1 CNN model structure

序号	名称	说明	可学习参数量	输出维度
1	Input	输入 $3 \times 1 \times 1$ 数据	—	$3 \times 1 \times 1$
2	BN	批标准化	偏移量 1×1 ; 缩放系数 1×1	$3 \times 1 \times 1$
3	Conv1	4个 5×5 卷积核	权重 $5 \times 5 \times 1 \times 4$; 偏置 $1 \times 1 \times 4$	$3 \times 1 \times 4$
4	ReLU1	ReLU激活函数	—	$3 \times 1 \times 4$
5	Conv2	8个 5×5 卷积核, 扩张系数[2 2]	权重 $5 \times 5 \times 4 \times 8$; 偏置 $1 \times 1 \times 8$	$3 \times 1 \times 8$
6	ReLU2	ReLU激活函数	—	$3 \times 1 \times 8$
7	Conv3	16个 5×5 卷积核, 扩张系数[2 2]	权重 $5 \times 5 \times 8 \times 6$; 偏置 $1 \times 1 \times 16$	$3 \times 1 \times 16$
8	ReLU3	ReLU激活函数	—	$3 \times 1 \times 16$
9	Conv4	32个 5×5 卷积, 扩张系数[2 2]	权重 $5 \times 5 \times 16 \times 32$; 偏置 $1 \times 1 \times 32$	$3 \times 1 \times 32$
10	ReLU4	ReLU激活函数	—	$3 \times 1 \times 32$
11	Dropout	Dropout 50%丢弃	—	$3 \times 1 \times 32$
12	FC	全连接层	权重 1×96 ; 偏置 1×1	$1 \times 1 \times 1$
13	Output	回归输出, MSE损失函数	—	$1 \times 1 \times 1$

3 模型预测结果与分析

3.1 数据与平台描述

本文中使用的数据集包含实地采集的入口压力与位移传感器数据以及对应的标签:入口压力、阀门位移为输入数据,出口压力作为标签。使用某仿真软件作为算法搭建的平台,对模型进行训练以及训练之后再进行测试集的评估。

3.2 呼吸变化趋势预测

选定呼吸数据中70%作为训练集、30%为测试集。训练30轮,每轮进行107次迭代,共进行3210次迭代。选定基础学习率0.2后开始训练,完成结果如图4所示。

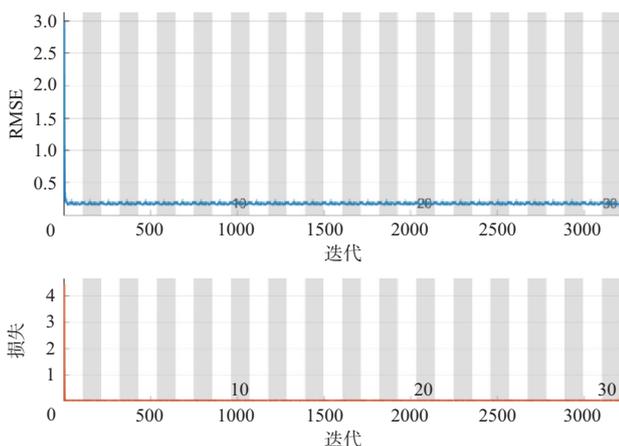


图4 模型训练结束图

Fig.4 Model training complete

由图4可知,损失函数和RMSE在训练初期就快速下降,说明该模型的训练进度快,收敛速度快。图5与图6展示了模型预测结果与预测误差图。

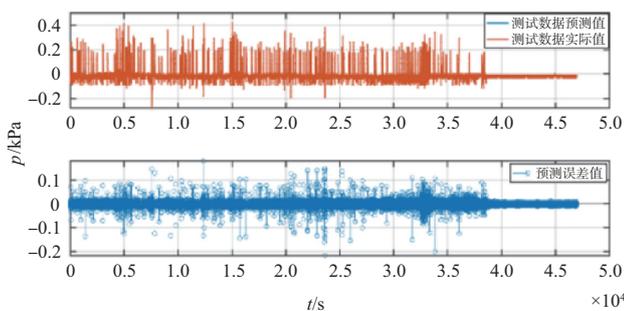


图5 预测值与真值对比图及误差图

Fig.5 Predicted value and true value comparison chart and error chart

训练结束后,模型损失函数MSE降至 8.9×10^{-5} ,MAE为 4.6×10^{-3} 。

模型输入包括当前时刻前15s的压力和位移数据,输出

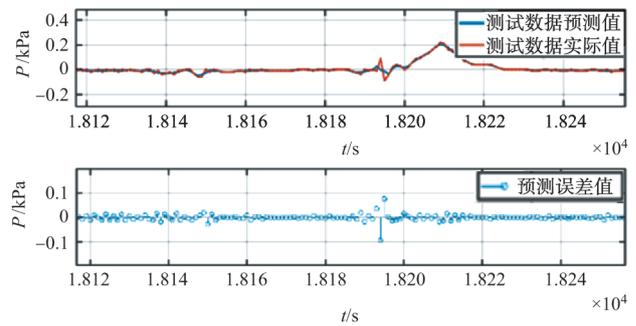


图6 预测值与真值对比图及误差的局部放大图

Fig.6 Predicted value and true value comparison chart and enlarged partial chart of error

则为当前时刻后15s的供氧出口压力。选择15s作为时间窗口是基于对呼吸过程的实时调节需求。前15s的数据能够充分捕捉到呼吸的短期变化和趋势,提供足够的历史信息以提高预测精度。而预测后15s的供氧出口压力则有助于在呼吸过程中进行及时调节,确保飞行员的呼吸舒适性和更高的氧气利用率。这一时长选择平衡了数据量和计算复杂度,既能够提供精确的实时调节,又不会增加系统的负担。

3.3 结果分析

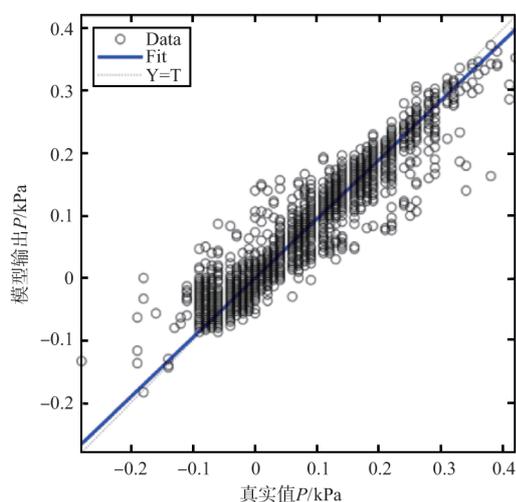
该模型的目的是在满足呼吸趋势变化预测准确性要求的同时,加快训练过程,提高CNN模型的效率。定义预测精度如下

$$A = 1 - \frac{\sum_{i=1}^N |y_i - \tilde{y}_i|}{\sum_{i=1}^N |y_i|} \quad (5)$$

式中, N 为测试集样本数; y_i 为实际值; \tilde{y}_i 为模型预测值。经计算,模型在测试集上的预测精度为92.422%。这里还列出了模型的 R^2 值,如图7所示。模型预测结果的 R^2 值约为0.981,说明预测模型具有良好的预测性能。

3.4 结果讨论

在考虑航空供氧系统中提前预测呼吸变化趋势以实现主动供氧的技术时,预测精度是衡量模型性能的关键指标之一。当预测精度为92%,并且是基于提前15s的预测时,需要从时间序列预测的角度深入分析这一精度的实际意义。首先,预测精度随着滑动时间窗口的前移而逐渐升高,能够提前15s预测呼吸变化趋势意味着模型能够在这段时间内根据预测结果主动调节氧气供应,从而优化飞行员的氧气利用效率和佩戴舒适性。其次,预测精度的评估不仅依赖于模型本身的准确性,还受到实际应用场景的影响。在航空供氧的应用中,即使预测精度达到92%,也存在8%的误差可能性。如果预测不准确,并不会停止供氧,而是退

图7 回归结果的 R^2 指标Fig.7 R^2 index of regression results

回到传统的呼吸面罩模式,即依靠飞行员的呼吸来推动阀门进行供氧,确保了在任何情况下都能为飞行员提供必要的氧气供应。从实际应用来分析,主动调节呼吸的要求不仅涉及预测精度的高低,还涉及系统的可靠性、安全性和用户体验。在这种情况下,92%的预测精度结合模型的冗余设计和容错机制,能够满足对主动调节呼吸的需求。同时,将此预测模型嵌入呼吸供氧系统能够在预测不准确时自动切换到传统模式,确保了飞行员的氧气供应不会因预测误差而中断,进一步增强了系统的安全性和可靠性。综上所述,预测精度为92%且能提前15s预测呼吸变化趋势的模型在航空供氧系统中是满足主动调节呼吸要求的。

4 结论

本文提出了一种基于CNN的人体呼吸变化趋势预测模型,旨在提升航空氧气面罩的舒适性与氧气利用率。通过研究,可以得出以下结论:

(1)构建了一种创新性的CNN模型,通过多层卷积、池化及全连接层的设计,实现了对入口压力与位移数据的有效特征提取和分析。

(2)通过测试集验证,模型对15s后的呼吸出口压预测精度达到92.422%,证明其能够准确捕捉呼吸过程中的变化趋势,具有良好的可行性和有效性。

(3)模型对人体呼吸趋势的预测,也是实现氧调器对人体呼吸阻力主动调节的基础。为呼吸防护装备的优化提供了新的思路和方法,展示了CNN在呼吸变化预测中的应用潜力,具有重要意义。

AST

参考文献

- [1] 王爽,王开通,曹金华,等.国外高速直升机的现状与发展趋势分析[J].航空科学技术,2023,34(12):1-8.
Wang Shuang, Wang Kaitong, Cao Jinhua, et al. Current situation and development trend analysis of high-speed helicopter [J]. Aeronautical Science & Technology, 2023, 34(12): 1-8. (in Chinese)
- [2] 张益凡,王宇超,张琴喻,等.基于眼动指标的飞行员注意状态识别可行性研究[J].航空科学技术,2022,33(4):39-46.
Zhang Yifan, Wang Yuchao, Zhang Qinyu, et al. Feasibility research on pilot attention state recognition based on eye metrics [J]. Aeronautical Science & Technology, 2022, 33(4): 39-46. (in Chinese)
- [3] 刘荣,姜南.头颈部防护装置对头颈部损伤的影响分析[J].航空科学技术,2022,33(11):84-89.
Liu Rong, Jiang Nan. Analysis on the effect of head and neck protection device on head and neck injury [J]. Aeronautical Science & Technology, 2022, 33(11): 84-89. (in Chinese)
- [4] 肖华军.航空供氧防护装备生理学[M].北京:军事医学科学出版社,2005.
Xiao Huajun. Aviation oxygen protection equipment physiology [M]. Beijing: Military Medical Science Press, 2005. (in Chinese)
- [5] 刘晓鹏,肖华军,付丽珊,等.飞行员氧气面罩渗气对其供氧防护效果的影响[J].解放军预防医学杂志,2004,22(5):335.
Liu Xiaopeng, Xiao Huajun, Fu Lishan, et al. The impact of oxygen mask leakage on the oxygen protection effectiveness for pilots[J]. Journal of Preventive Medicine of the PLA, 2004, 22(5): 335. (in Chinese)
- [6] Corey E L. Pilot Metabolism and respiratory activity during varied flight tasks[J]. Journal of Applied Physiology, 1948, 1(1):35-44.
- [7] Nemat S, Malhotra A, Clifford G. Data fusion for improved respiration rate estimation[J]. Eurasip Journal on Advances in Signal Processing, 2010(1):926305.
- [8] Wilson G F, Fullenkamp P, Davis I. Evoked potential, cardiac, blink, and respiration measures of pilot workload in air-to-ground missions[J]. Aviation Space and Environmental Medicine, 1994, 65(2):100-105.
- [9] Stuber M, Ren M B, Danias P G, et al. Contrast agent-

- enhanced, free-breathing, three-dimensional coronary magnetic resonance angiography[J]. *Journal of Magnetic Resonance Imaging*, 2015,10(5):790-799.
- [10] 鲍岚, 张立藩. 飞行中人体的呼吸生理反应[J]. *中华航空医学杂志*, 1994, 5(2):123.
Bao Lan, Zhang Lifan. Respiratory physiological responses of the human body during flight[J]. *Chinese Journal of Aerospace Medicine*, 1994, 5(2): 123. (in Chinese)
- [11] 张立藩. 呼吸阻力负荷心理-生理研究进展[J]. *中华航空医学杂志*, 1991, 2(1):1.
Zhang Lifan. Advances in psycho-physiological research on respiratory resistance load[J]. *Chinese Journal of Aerospace Medicine*, 1991, 2(1): 1. (in Chinese)
- [12] 祝筱姬. 飞行员飞行中的呼吸生理与防护国内研究现状[J]. *实用医药杂志*, 2007(6):746-747.
- Zhu Xiaoji. Current status of domestic research on respiratory physiology and protection of pilots during flight[J]. *Practical Medicine Journal*, 2007(6): 746-747. (in Chinese)
- [13] 肖华军. 航空供氧装备与防护生理学的发展历程[J]. *解放军医学杂志*, 2004, 29(10): 833.
Xiao Huajun. Development history of aviation oxygen equipment and protective physiology[J]. *Medical Journal of the Chinese People's Liberation Army*, 2004, 29(10): 833. (in Chinese)
- [14] Graves A. Supervised sequence labelling with recurrent neural networks[M]. Berlin: Springer, 2012.
- [15] Schmidhuber J. Deep learning in neural networks: an overview [J]. *Neural Networks*, 2015, 61: 85-117.

Prediction Model of Respiratory Trend Based on Convolutional Neural Networks

Li Yuwen^{1,2}, Tian Yuepeng¹, Qi Xiaoling², Gan Junjie², Huang Dong¹, Zhang Zhimin³

1. *Southeast University, Nanjing 210096, China*

2. *Key laboratory of Aeronautical Science and Technology for Aeronautical Protection and Life-Saving Technology, AVIC Aerospace Life-Support Industries, Ltd., Xiangyang 441003, China*

3. *China Pharmaceutical University, Nanjing 211198, China*

Abstract: In the aerospace field, the physiological health of pilots is closely related to flight safety, and the comfort and oxygen utilization of breathing gas masks are key factors. Traditional aviation oxygen masks mainly use built-in sensors to complete lagging breathing gas valve adjustment, and users often feel that the mask has high breathing resistance and poor wearing comfort. In order to improve the pilot's operating experience and safety, this paper establishes a breathing change trend prediction model, aiming to provide a new solution for active regulation of breathing oxygen supply in respiratory protection. By proposing a prediction model based on convolutional neural network (CNN) algorithm, which predicts the outlet pressure data 15s later based on the corresponding breathing data collected by the inlet pressure and displacement sensors, the breathing change trend is predicted, thus achieving active oxygen supply and regulation of breathing. The research results show that the accuracy of the breathing change trend prediction model proposed in this paper is 92.422%. This model can improve the comfort and oxygen utilization of oxygen masks, and is of great significance for respiratory protection.

Key Words: respiratory prediction; deep learning; CNN; active regulation

Received: 2024-04-09; **Revised:** 2024-08-26; **Accepted:** 2024-11-04

Foundation item: Aeronautical Science Foundation of China(20200029069001)