DOI:10.13193/j.issn.1673-7717.2025.08.004

基于卷积-自注意力机制对多周期脉象识别分类

邓威[1],刘轩吉[1],郝龙辉[1],朱子简[2],李飞[3],王蕊[4],刘克勤[4],郭鹏宇[2],周华[2],王维广[5],陈占春[1]
(1.太原理工大学机械工程学院,山西 太原 030024;2.上海贝业斯健康科技有限公司,上海 201600;
3.山西省针灸医院,山西 太原 030006;4.太原市中医院,山西 太原 030009;
5.北京中医药大学中医学院中医基础理论系,北京 100029)

摘要:传统单周期脉象识别面临形态复杂、周期异变和个体差异等挑战,限制了其在实际应用中的有效性。本研究专注于解决多周期脉象识别分类问题,通过马尔可夫转移场融合脉象信号的幅值与时序信息,构建了新的图像数据集。基于此,提出了一种新的网络模型——对于卷积-注意力网络模型(Temporal convolutional attention network,TCANet),该模型结合深度可分离卷积和自注意力机制,显著提升了脉象图像数据的识别分类能力。实验结果显示,TCANet在滑脉、弦脉、平脉等脉象识别任务中分别达到了94.74%的准确率、94.79%的精确率、94.74%的召回率和94.76%的F1分数,表明其在多周期脉象识别领域具备优异的性能和广泛的应用潜力。

关键词: 多周期脉象;脉象识别;马尔可夫转移场;深度可分离卷积;自注意力
中图分类号:R241.1 **文献标志码:**A **文章编号:**1673-7717(2025)08-0013-09

Multi-period Pulse Recognition Based on Convolutional and Self-Attention Model

DENG Wei[1],LIU Xuanji[1],HAO Longhui[1],ZHU Zijian[2],LI Fei[3],WANG Rui[4],LIU Keqin[4],
GUO Pengyu[2],ZHOU Hua[2],WANG Weiguang[5],CHEN Zhanchun[1]
(1.College of Mechanical Engineering,Taiyuan University of Technology,Taiyuan 030024,Shanxi,China;
2.Shanghai Beyers Health Technology Co. Ltd,Shanghai 201600,China;
3.Shanxi Acupuncture and Moxibustion Hospital,Taiyuan 030006,Shanxi,China;
4.Taiyuan Traditional Chinese Medicine Hospital,Taiyuan 030009,Shanxi,China;
5.Institute of Basic Research in Clinical Medicine,China Academy of Chinese Medical Sciences,
Beijing University of Chinese Medicine,Beijing 100029,China)

Abstract:*Objective* The traditional single-cycle pulse recognition methods encounter significant limitations in practical applications due to the morphological diversity,cycle variability and individual differences inherent in the wrist pulse signals. In this study,it focused on solving the classification problem of multi-period pulse recognition,and constructed an image-based dataset by integrating the amplitude and temporal information of pulse signal through the Markov Transition Field(MTF). Building upon this foundation,it set up new deep-learning network model,TCANet(Temporal Convolutional Attention Network),which leveraged the depth-wise separable convolutions and self-attention mechanisms to markedly improve the accuracy and efficiency of pulse image classification. The experimental outcomes revealed that TCANet achieved the impressive performance metrics,including 94.74% accuracy,94.79% precision,94.74% recall and 94.76% F1 score in recognizing the slippery, stringy and normal wrist pulses. This indicated that it had excellent performance and wide application potential in the field of multi cycle pulse recognition.

Keywords:multi-period pulse;pulse classification;MTF;depth-wise separable convolution;self-attention

---

基金项目:国家自然科学基金项目(52075361);科技部科技基础资源调查专项(2022FY102000,2022FY102002);山西省科技重大专项(20201102003);中央高校基本科研业务费专项(2022-JYB-JBZR-011);太原市卫生健康委员会中医人工智能医生工作室研发创新团队项目(ZYYTD2024035);山西浙大新材料与化工研究院项目(2022SX-TD021)

作者简介:邓威(1998-),男,重庆人,硕士在读,研究方向:人工智能。
通讯作者:陈占春(1979-),男,山西吕梁人,副教授,硕士研究生导师,研究方向:医学人工智能。E-mail:chenzhanchun@tyut.edu.cn。
刘克勤(1968-),男,山西太原人,主任中医师,硕士研究生导师,研究方向:中医内科脾胃病。E-mail:lkqty@126.com。

中医在我国具有悠久的发展历史,脉诊是传统中医的重要组成部分,经过几千年的传承和发展,逐步确立了诊断手法及不同的脉象类型,已成为中医临床诊断中不可缺少的一部分。《黄帝内经》《难经》为脉学之宗,历来为研究者所重视,如《素问·脉要精微论篇》云:"微妙在脉,不可不察。"脉搏是人体心血系统循环所产生的搏动,其中蕴含了人体丰富的生理及病理信息。然而,传统中医依据脉诊经验这一诊断方法难以普及,同时脉象变化至精至微,这导致对脉象标准化、客观化更加困难[1-2]。

近几年,人工智能发展迅速,借鉴人类视觉系统特点而提出的注意力机制,广泛应用在自然语言处理、图像识别、语音识别等不同类型的深度学习任务当中。卷积神经网络(Convolutional neural networks,CNN)在图像领域备受青睐[3],许多研究人员将注意力机制应用到卷积神经网络上,以便学习到更关键、更深层的信息[4-6]。此外,Transformer因采用自注意力机制[7],不仅在自然语言领域大放异彩,还在图像领域有许多应用[8-10]。

随着人工智能及压电材料的逐步发展,研究人员通过计算机和传感器将脉象经过一系列预处理,得到原始脉象数据信号,再通过中医理论对脉象信号进行分类识别。不少人将脉象与卷积、注意力机制结合起来[11-17]。朱嘉健等[11]结合残差网络和通道注意力机制,对一维单周期脉象进行识别分类,准确率达到了99.64%。朱光耀等[12]建立了一种基于残差块的时序卷积神经网络(Temporal convolutional network,TCN),识别单周期脉象达到了85.76%的准确率。CHEN X F等[17]提出了不同尺寸卷积核的卷积神经网络模型(Multi-kernel convolutional neural network,Mk-CNN),对标准化后的单周期脉象识别准确率达到了91.94%。刘轩吉等[18]结合卷积神经网络和残差块,提出了传统中医脉象识别网络模型(Traditional Chinese Pulse Network,TCPNet),并在多周期脉象识别分类任务中达到93.61%的准确率。LIU Q C等[19]结合长短期记忆递归神经网络(Long short term memory,LSTM)和Transformer,提出了生理信号分类网络模型(Physiological signal classification network,PSC-Net),并在单周期脉象分类识别中达到了83.33%的正确率。然而,脉象信号复杂多变,且同一脉象在不同个体间也可能表现不同,进而影响脉象分类的准确率。不仅如此,单周期脉象分类就不得不实现周期划分,而这又面临脉象形态多样和周期长度异变等挑战,导致单周期脉象识别分类在实际应用中存在显著局限性[20]。

因此,本研究采用的脉象数据仅需经过低通滤波处理,以降低数据集制作成本。数据集包含4种脉象,分别为滑脉、弦脉、平脉和其他脉[21]。其中,滑脉、弦脉和平脉如图1所示;同时,为了更好地提高模型的识别分类能力,利用马尔可夫转移场(Markov transition field,MTF)融合了脉象原始数据中的幅值和时序信息[22],以此生成的图像作为数据集。

本文结合卷积和自注意力机制,提出了时序卷积-注意力网络模型(Temporal convolutional attention network,TCANet),对四类脉象信号进行识别分类。此外,深度可分离卷积模块结合了通道注意力机制模块[23],让模型偏重信息更加关键的通道。

1 方法

1.1 概述 多周期脉象识别流程如插页Ⅲ图2所示,先将一维多周期脉象信号通过马尔可夫转移场转换为二维时序图像,再结合深度可分离卷积和自注意力机制,搭建TCANet各版本网络模型,然后对二维时序图像数据集进行识别分类训练,纵向分析实验结果并据此进行调参和优化,最后根据各模型在脉象识别任务中的性能表现,得到综合性能最好的网络模型。除此之外,本文还引入了刘轩吉等提出的多周期脉象分类模型,即TCPNet,作为外部参照模型,横向对比各性能指标差异。

1.2 马尔可夫转移场 马尔可夫转移场是一种时间序列图像编码方法,如插页Ⅲ图3所示,它先将脉象数据的幅值分成Q个分位数区间,然后构建Q×Q的马尔可夫转移矩阵,最后结合时序信息生成马尔可夫转移场矩阵。生成的图像包含了脉象数据中丰富的时域信息,表现出脉象的复杂性,进一步提高模型分辨能力。

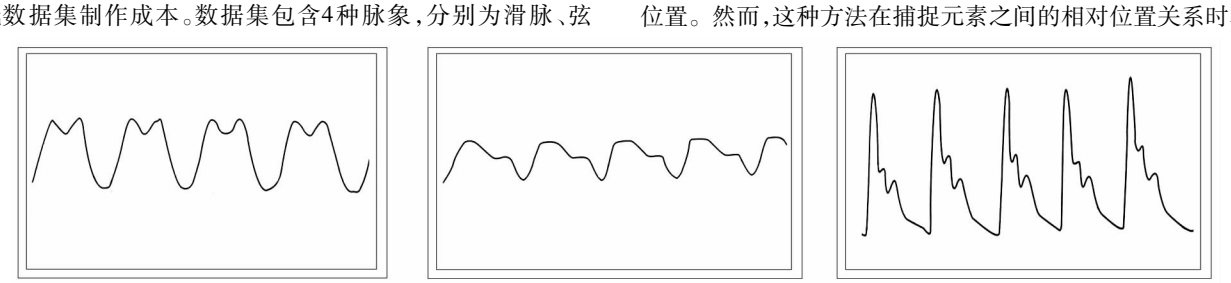
1.3 深度可分离卷积(Depthwise Separable Convolution) 传统卷积采用多个卷积核对图像进行卷积,参数量和运算量比较大。为了大幅减少训练资源,采用了深度可分离卷积[24],它由逐通道卷积(Depthwise Convolution)和逐点卷积(Pointwise Convolution)两部分组成,卷积过程如插页Ⅲ图4所示。

逐通道卷积核是单通道卷积,即一个卷积核只针对输入图像的单个通道进行卷积;逐点卷积则是通过1×1的卷积核转换输入特征图的维度。对于一个输入序列$x=(x_1,x_2,\cdots,x_n)$,经过卷积运算,得到输出$y=(y_1,y_2,\cdots,y_n)$。运算如公式(1)所示:

$$y_i=\sum_{j\in L(i)} w_{i-j}\odot x_j \tag{1}$$

其中,x_i、$y_i\in R^n$,分别为在位置i的输入和输出,$L_{(i)}$为位置i附近的邻域。

1.4 相对自注意力机制(Relation-aware Self-attention) 传统Transformer没有显式地构建相对或绝对位置信息,所以自注意力机制需要添加绝对位置编码来表示序列中每个元素的位置。然而,这种方法在捕捉元素之间的相对位置关系时不够



(a)滑脉 (b)弦脉 (c)平脉

图1 滑脉、弦脉、平脉脉象示意图

有效。如插页Ⅳ图 5 所示，相对自注意力机制将输入图像不同元素之间的相对位置信息组成一个矩阵，从而更好地捕捉序列中元素之间的相对位置关系。对于两个元素 x_i、x_j，它们之间的输出 y_i 如公式(2)所示：

$$y_i = \sum_{j \in G} \frac{\exp(x_i^T x_j + \beta_{i-j})}{\sum_{k \in G} \exp(x_i^T x_k + \beta_{i-k})} x_j \quad (2)$$

其中，β_{i-k}表示 x_i、x_k 之间的相对位置，G 表示全局空间。卷积和相对自注意力融合到一起，如公式(3)所示：

$$y_i^* = \sum_{j \in G} \left[\frac{\exp(x_i^T x_j + \beta_{i-j})}{\sum_{k \in G} \exp(x_i^T x_k + \beta_{i-k})} + w_{i-j} \right] x_j \quad (3)$$

1.5 TCANet 网络模型 TCANet 网络模型的设计灵感来源于残差网络(Residual networks，ResNet)、轻量级网络模型(Mobile network，MobileNet)和卷积注意力模型(Convolution - attention network，CoAtNet)。其中 ResNet 是由 HE K M 等[25]提出的，他们通过残差连接，成功训练了 152 层的卷积神经网络，并取得了良好的训练效果，解决了网络模型随着层数增加而难以优化的问题。MobileNet 是 Google 提出的轻量级模型，MobileNet - V1[24]采用深度可分离卷积，在几乎不减少准确率的情况下极大地减少了参数量；MobileNet - V2[26]灵活使用“倒残差”结构和线性激活函数，进一步降低了信息损失量，达到了更好的训练效果；MobileNet - V3[23]引入通道注意力机制模块(Squeeze - and - excitation networks，SENet)，从而利用全局信息来增强有用的信息，同时抑制无用的信息。CoAtNet 是由 DAI Z 等[10]将卷积和自注意力机制结合起来而提出的，它同时具备了 CNN 和 Transformer 的优势。

基于以上几种网络模型的优良性能，本文提出了 TCANet 网络模型，为了研究该模型的性能，设计了 TCANet 的不同版本——包含不同数量、位置的自注意力模块。由于自注意力模块运算量大，故将自注意力模块布置在卷积层之后。定义的模块如表 1 和插页Ⅳ图 6 所示，其中卷积模块(Mobile convolution，MBConv)利用可分离卷积，结合通道注意力机制和残差连接，不仅极大地降低了参数量和运算量，而且可以保留效果好的训练层，在获取更高精度的同时还可以避免梯度消失或者梯度爆炸的问题。通道注意力模块将全局信息压缩成只关于通道信息的一维向量，并经过高斯误差线性单元激活函数(Gaussian error linear unit，GELU)[27]和 Sigmoid 两层激活函数，增强模型的学习表达能力。

表 1 TCANet 网络定义的模块

MBConv(m,n)	SE(m,n)	FC(m,n)	CA(m,n)
Conv(k,s,n)	AvgPool(1)	Linear(m,n)	MaxPool(k,2)
BatchNorm(n)	Linear(m,n/16)	Hard - Swish()	LayerNorm(n)
GELU()	GELU()	Linear(n,n)	Rel - Attention(n)
Conv(k,s,n)	Linear(n/16,n)		MaxPool(k,2)
BatchNorm(n)	Sigmoid()		Conv(k,s,n)
GELU()			Residual()
SE(m,n)			LayerNorm(n)
Conv(k,s,n)			FC(m,n)
BatchNorm(n)			LayerNorm(n)
Residual()			

注：Residual()为残差连接，k 为卷积核大小，s 为步长，m 为输入通道数，n 为输出通道数。

CA 模块(Convolutional attention)通过两层最大池化层将输入尺寸缩小，降低自注意力和卷积运算量，并通过残差连接将两者融合到一起，最后输出到全连接层。全连接层(Fully Connection，FC)采用了 Hard - Swish 激活函数，它具有良好的数字稳定性，可以在计算中避免数值溢出或数值不稳定的情况，同时计算成本较低，计算速度较快，特别是在深层网络中有良好的表现。插页Ⅳ图 7 为 TCANet(C)的网络模型示意图，它包含了两层标准卷积(Convolution，Conv)，2 个 MBConv 模块，2 个 CA 模块和 1 个全连接输出层。

2 实验

2.1 数据来源 脉象信号采集设备是由太原理工大学和上海贝业斯公司共同研发的脉诊仪，以测量人体腕部寸关尺的脉象信号。采集的信号数据来源于太原市中医院，采样频率为 125 Hz，采集时间为 5 s，采样点为 625 个。

表 2 TCANet 网络的不同版本

网络层	Baseline	TCANet(A)	TCANet(B)	TCANet(C)	TCANet(C_1)
Layer1	Conv(3,2,192)	Conv(3,2,192)	Conv(3,2,192)	Conv(3,2,192)	Conv(3,2,64)
	Conv(3,1,192)	Conv(3,1,192)	Conv(3,1,192)	Conv(3,1,192)	Conv(3,1,64)
Layer2	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)
	Conv(1,1,192)	Conv(1,1,192)	Conv(1,1,192)	Conv(1,1,192)	Conv(1,1,128)
	MBConv(192) *2	MBConv(192) *2	MBConv(192) *2	MBConv(192) *2	MBConv(128) *2
Layer3	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	
	Conv(1,1,384)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)
	MBConv(384) *2	CA(384) *2	MBConv(384) *2	MBConv(384) *2	MBConv(256) *2
Layer4	MaxPool(3,2)		MaxPool(3,2)		
	Conv(1,1,768)	MaxPool(3,2)	Conv(1,1,768)	MaxPool(3,2)	MaxPool(3,2)
	MBConv(768) *2	CA(768) *2	MBConv(768) *2	CA(768) *2	CA(512) *2
Layer5	MaxPool(3,2)				
	Conv(1,1,1536)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)
	MBConv(1536) *2	CA(1536) *2	CA(1536) *2	CA(1536) *2	CA(1024) *2
Layer6	AveragePool (1)	AveragePool (1)	AveragePool (1)	AveragePool (1)	AveragePool (1)
	FC(4)	FC(4)	FC(4)	FC(4)	FC(4)

注：MBConv()，CA()，FC()中的数字为输出通道数，AveragePool()中 1 为步长，*2 表示该模块数量为 2。

2.2 数据预处理 脉诊仪采集的脉象信号通常包含高频噪声,因此必须进行滤波处理。数据中的高频噪声源包括白噪声、工频干扰和人体电极极化干扰,频率主要分布在 10 ~ 50 Hz。而实验目标脉搏波数据的频率为 0.7 ~ 3.0 Hz,故采用低通滤波滤除 10 Hz 以上的噪声。这种方法能够有效去除高频噪声,同时保留脉搏波中的生理病理信息。

2.3 脉象数据集 采集到的数据共计 6208 例,用相应的脉象类别标签标记每一个信号段。预处理后的数据为滑脉 1554 个,弦脉 1487 个,平脉 1501 个,其他脉(非弦脉滑脉)1666 个。

2.4 评价指标 采用分类模型研究中常用的准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 分数($F1_{score}$)以及混淆矩阵(Confusion Matrix)作为评价模型的性能指标。混淆矩阵能直观地显示模型的分类结果,并能通过分析混淆矩阵中的各个元素,计算各个性能指标,全面分析模型的性能。

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \tag{4}$$

$$Precision = \frac{TP}{(TP + FP)} \tag{5}$$

$$Recall = \frac{TP}{(TP + FN)} \tag{6}$$

$$F1_{score} = \frac{(2 \times Precision \times Recall)}{(Precision + Recall)} \tag{7}$$

TP、TN、FP 和 FN 分别代表实际为正类、实际为负类、错误预测为正类和错误预测为负类的样本数量。准确率衡量的是模型正确预测的样本占总样本的比例;精确率表示在所有被预测为正类的样本中,实际为正类的比例;召回率表示的是模型对实际正类样本的识别能力;F1 分数是评价数据不均衡时模型性能的指标。此外,因为脉象数据各类数量比例接近,数据集总体相对平衡,所以 4 种评价指标采用宏平均计算。

2.5 参数设置 通过 Pytorch 框架搭建了 TCANet 网络模型,采用带权重衰减项的自适应矩估计(Adam with weight decay fix,Adamw)优化器进行训练,它在自适应矩估计(Adaptive moment estimation,Adam)优化器的基础上优化了权重衰减,可以提高模型的训练效果。为了彻底发掘自注意力模块的能力,本实验的超参数采用了 epoch = 200,初始化学习率为 1e - 4,批量大小为 16,训练集: 验证集: 测试集 = 8 ∶ 1 ∶ 1。实验采用的 GPU 显卡为 NVIDIA GeForce RTX 3090。

3 讨论

3.1 实验结果 对照组(Baseline)全部将对应的 CA 模块替换成 MBConv 模块,TCANet 各个网络的注意力模块位置和数量不同,以此研究深度可分离卷积和注意力机制对脉象识别分类的效果。TCANet 各版本网络模型的训练结果如表 3 所示。

表 3 脉象模型分类结果

脉象模型	准确率/(%)	精确率/(%)	召回率/(%)	$F1_{score}$/(%)	模型大小/(MB)
TCPNet	89.47	90.23	89.47	89.85	515.88
Baseline	9.59	9.75	9.59	9.67	89.22
TCANet(A)	94.08	94.20	94.08	94.14	178.09
TCANet(B)	94.41	94.43	94.41	94.42	146.02
TCANet(C)	**94.74**	**94.79**	**94.74**	**94.76**	163.21
TCANet(C_1)	9.58	9.70	9.58	9.64	**29.19**

注:加粗的数字表示 TCANet 模型最好的性能。

如插页Ⅴ图 8 所示,相比于 TCPNet,采用了深度可分离卷积的模型内存大幅降低,这证明了深度可分离卷积对参数运算量和模型内存大小的降低效果十分显著。此外,如果适当减少通道数,可以在轻微降低模型性能的情况下,大幅降低了模型大小。如 TCANet(C_1)的内存大小为 29.19 MB,分别占 TCPNet 和 TCANet 大小的 5.66%、17.88%。这一特性大大增强了模型的实用性,可根据需求应用在不同场景。如插页Ⅴ图 8(a)所示,在通道数相等的情况下,包含自注意力模块的网络模型性能比全部采用卷积的网络模型更好。

根据 TCANet(A)和 TCANet(B)的训练结果可以看出,与对照组相比,TCANet(A)在网络浅层用自注意力模块代替 MBConv 模块,导致全局空间尺寸较大,计算量和参数量急剧增加,同时减少了 MBConv 卷积模块,从而模型泛化能力降低,故在测试集上表现不如 TCANet(B)。与之相反,TCANet(B)只在网络深层采用了自注意力模块,如插页Ⅴ图 9 中层 5 所示,输入图片尺寸为 7 × 7,这导致包含高维信息过少,从而限制了网络模型的学习能力,所以 TCANet(B)性能表现不如 TCANet(C)。

TCANet(C)前三层网络采用卷积,因为卷积的计算复杂度较低,并通过局部感受野和参数共享机制,能够高效地提取脉象图像中的边缘、纹理等局部特征。如图 9 所示,在层 4 和层 5 采用了两层自注意力机制捕获全局空间信息,二者都捕捉到了卷积层之外的信息,再与卷积模块收集的局部信息进行残差连接,有效地扩大了感受野,从而增强了模型的学习能力、表达能力和鲁棒性,提高了脉象识别各项指标。这就表明,相对自注意力机制能够捕获图像中所有像素之间的全局依赖关系,识别跨越整个图像的长距离特征。同时自注意力机制能够根据输入的特定内容动态调整权重,更灵活地表达像素之间的关系,这种动态加权能力更适合复杂多变的脉象图像识别,从而提高模型的脉象识别能力。

为了深入研究深度可分离卷积和自注意力的作用,本实验在 TCANet(C)的框架基础上,在层 3 和层 4 值间增加不同数量的 MBConv 模块和 CA 模块,其余部分和 TCANet(C)一样,如表 4 所示。对应训练结果如插页Ⅴ图 10 所示。

表 4 TCANet(D - G)网络框架

网络层	TCANet(D)	TCANet(E)	TCANet(F)	TCANet(G)
Layer3	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)
	Conv(1,1,384)	Conv(1,1,384)	Conv(1,1,384)	Conv(1,1,384)
	MBConv(384) *3	MBConv(384) *2	MBConv(384) *3	MBConv(384) *5
Layer4	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)	MaxPool(3,2)
	CA(768) *3	CA(768) *5	CA(768) *9	CA(768) *12

如图 10 所示,CA 模块在准确率、精确率、召回率和 $F1_{score}$ 这几个指标上均高于 MBConv 模块,这表明自注意力模块可以提高模型学习能力的上限,但需要付出更多的训练资源。另一方面,随着自注意力模块的增加,并没有显著地提高模型能力,对应的评价指标反而有一些下降,这可能是因为数据集数量较少,与模型的能力不相匹配。

测试集共 608 个样本,其中滑脉 153 个,弦脉 145 个,平脉 147 个,其他脉 163 个。如插页Ⅵ图 11 所示,TCPNet 在弦脉的识别表现上最好,全部识别正确,而在另外三种脉象上均落后;它在滑脉中有 15 个脉象识别错误,平脉识别错误有 18 个,其

他脉识别错误高达 31 个。与之相比,TCANet(C)正确识别滑脉 142 条,2 条识别成弦脉,也有 4 条识别成平脉,5 条识别成其他脉;正确识别弦脉 144 条,1 条识别成平脉;正确识别平脉 143 条,1 条识别成滑脉,2 条识别成弦脉,1 条识别成其他脉;正确识别其他脉 147 条,14 条识别成滑脉,2 条识别成平脉。

TCANet(C)在 4 种脉象识别分类上达到了 94.74% 的准确率,94.79% 的精确率,94.74% 的召回率,F1 分数为 94.76%。相比于 TCPNet,TCANet(C)在脉象识别数据集上的准确率提高了 5.27%,精确率提高了 4.56%,召回率也提高了 5.27%,$F1_{score}$ 提高了 4.91%,模型内存缩小 68.36%,降低了 352.67 MB。这充分体现了自注意力机制和深度可分离卷积相结合的优越性,为中医脉象识别分类提供了新的思路和方法。

3.2 结论 传统的单周期脉象识别面临着脉搏形态多样性、周期长度变化和个体差异等复杂挑战,因而在实际应用中存在显著局限性。针对识别多周期脉象信号时,本文提出了一种新颖的脉象识别分类模型——TCANet。该模型结合了深度可分离卷积和自注意力机制,有效克服了脉象信号复杂性的挑战,实现了对多周期脉象信号的精准分类。实验结果显示,TCANet 模型在脉象识别中的准确率为达到了 94.74%,精确率达到了 94.79%,召回率达到了 94.74%,F1 分数达到了 94.76%。这些结果充分验证了 TCANet 模型在脉象识别领域的有效性和先进性,为中医脉象信号的智能分析与诊断开辟了新的途径,展现出良好的应用前景。

参考文献

[1] 周春祥. 名老中医经验总结与传承过程中的问题与思考[J]. 江苏中医药, 2004, 36(12): 1-4.
[2] 王维斌, 陈锦明, 俞洁. 临床脉诊面临困境的原因及对策[J]. 中医药通报, 2019, 18(6): 29-32.
[3] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA. IEEE, 2022: 11966-11976.
[4] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 7132-7141.
[5] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]// Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
[6] WANG Q L, WU B G, ZHU P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020.
[7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 48550.
[8] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 9992-10002.
[9] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J/OL]. http://arxiv.org/abs/2010.11929.
[10] DAI Z, LIU H, LE Q V, et al. Coatnet: Marrying convolution and attention for all data sizes[J]. Advances in Neural Information Processing Systems, 2021, 34: 3965-3977.
[11] 朱嘉健, 冯跃, 徐红, 等. 基于残差网络与注意力机制的脉象信号分析识别[J]. 现代电子技术, 20, 46(7): 57-66.
[12] 朱光耀, 颜建军, 郭睿, 等. 基于时间序列和时序卷积网络的脉象信号识别研究[J]. 世界科学技术-中医药现代化, 2021, 23(9): 3056-3064.
[13] 颜建军, 陈松晔, 燕海霞, 等. 基于递归图和卷积神经网络的脉象分析识别[J]. 计算机工程与应用, 2020, 56(7): 170-175.
[14] 张嘉琪, 张月琴, 陈健. 优化强化学习路径特征分类的脉象识别法[J]. 计算机应用, 2021, 41(11): 3402-3408.
[15] PATIL N, RAI S, NAGARE G. Classification of peripheral pulse morphology using convolutional neural networks[C]//2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM). Noida, India: IEEE, 2024: 1-6.
[16] TAGO K, WANG H D, JIN Q. Classification of TCM pulse diagnoses based on pulse and periodic features from personal health data[C]//2019 IEEE Global Communications Conference (GLOBECOM). Waikoloa, HI, USA: IEEE, 2019: 1-6.
[17] CHEN X F, XU H, QIAN P, et al. Multi-kernel convolutional neural network for wrist pulse signal classification[C]//2022 32nd Conference of Open Innovations Association (FRUCT). Tampere, Finland: IEEE, 2022: 75-86.
[18] 刘轩吉, 刘光浚, 邓威, 等. 基于 GASF 及神经网络的多周期脉象信号识别分类研究[J]. 中华中医药学刊, 2024, 42(10): 22-27, 261-262.
[19] LIU Q C, FENG Y, XU H, et al. PSC-net: integration of convolutional neural networks and transformers for physiological signal classification[J]. Biomed Signal Process Contr, 2024, 91: 106040.
[20] SHAW P, USZKOREIT J, VASWANI A. Self-attention with relative position representations[J]. arXiv E Prints, 2018, 2018: 1803.
[21] 彭清华, 谢梦洲. 中医脉诊临床图解[M]. 北京: 化学工业出版社, 2019: 19-68.
[22] WANG Z, OATES T. Imaging time-series to improve classification and imputation[J]. Arxiv Preprint Arxiv, 2015, 1506: 327.
[23] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019: 57-89.
[24] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. 2017: 1704.04861. https://arxiv.org/abs/1704.04861v1.
[25] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770-778.
[26] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 4510-4520.
[27] HENDRYCKS D, GIMPEL K. Gaussian error linear units (*GELUs*)[EB/OL]. 2016: 1606.08415. https://arxiv.org/abs/1606.08415v5.

基于卷积－自注意力机制对多周期脉象识别分类

（正文见 13－17 页）

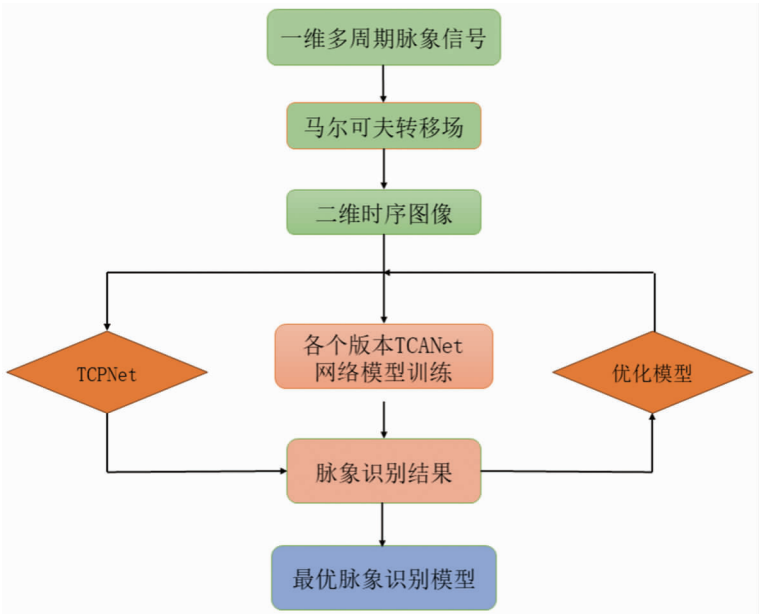


图 2　脉象信号分类流程示意图

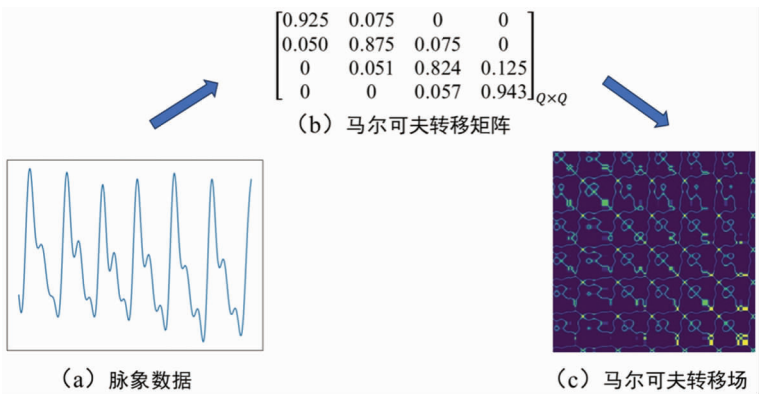


图 3　MTF 处理脉象信号示意图

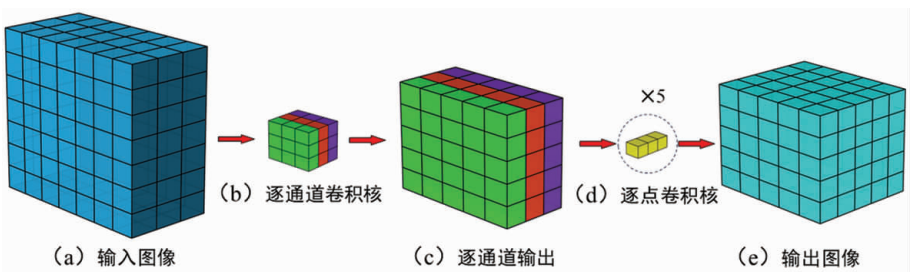


图 4　深度可分离卷积示意图

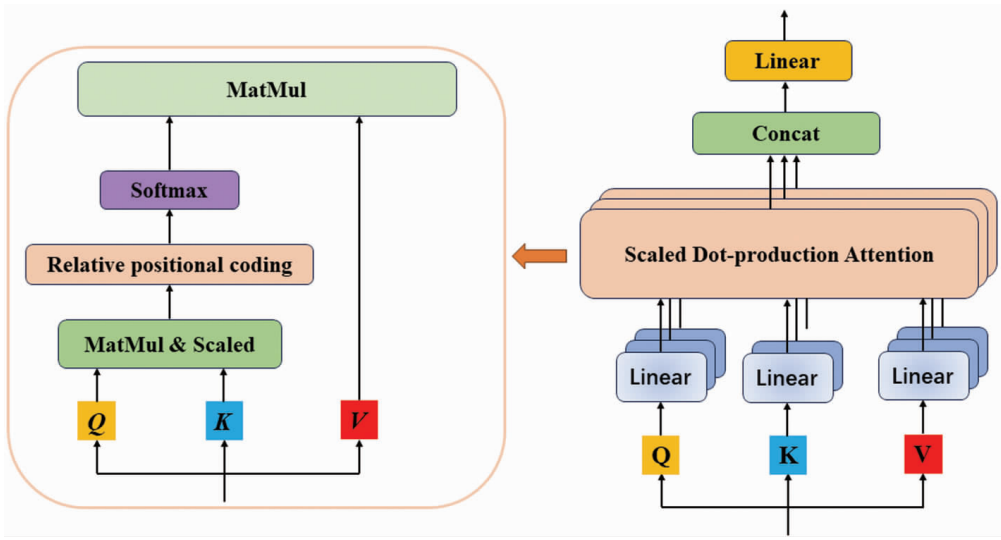


图 5 相对自注意力机制示意图

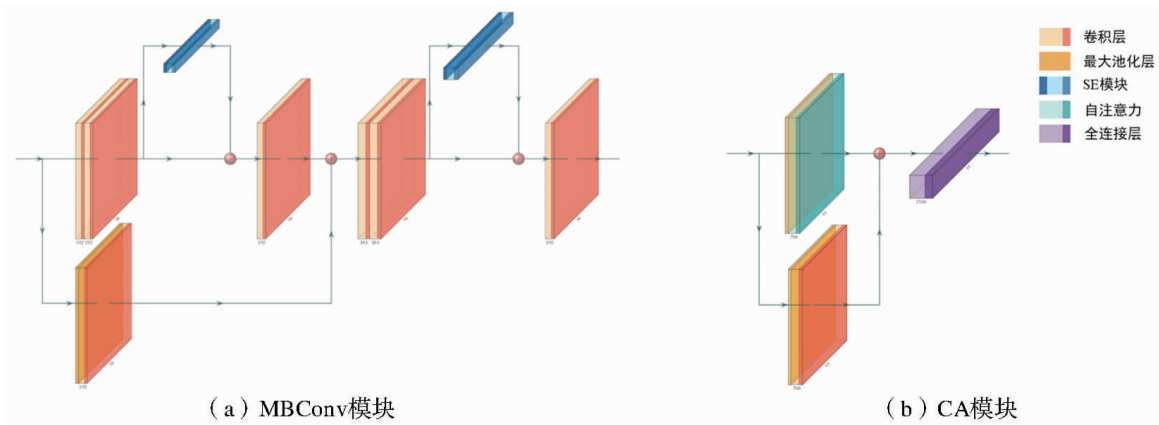


图 6 TCANet 定义模块示意图

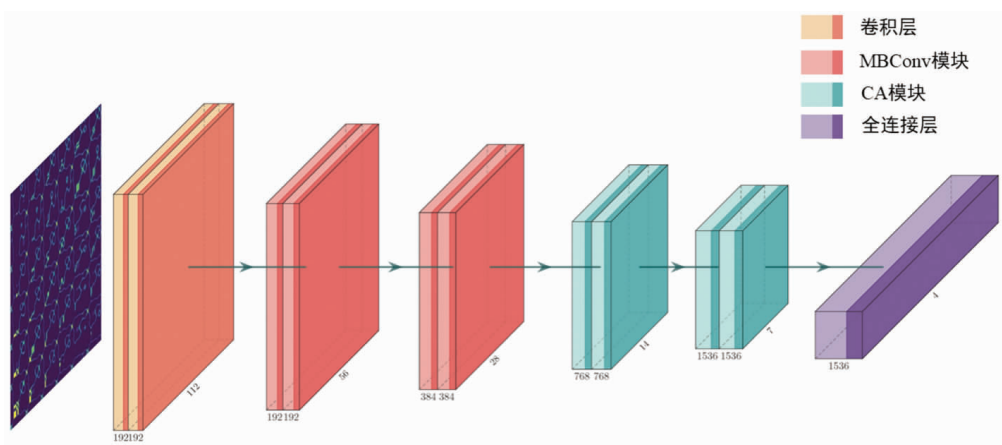


图 7 TCANet（C）模型示意图

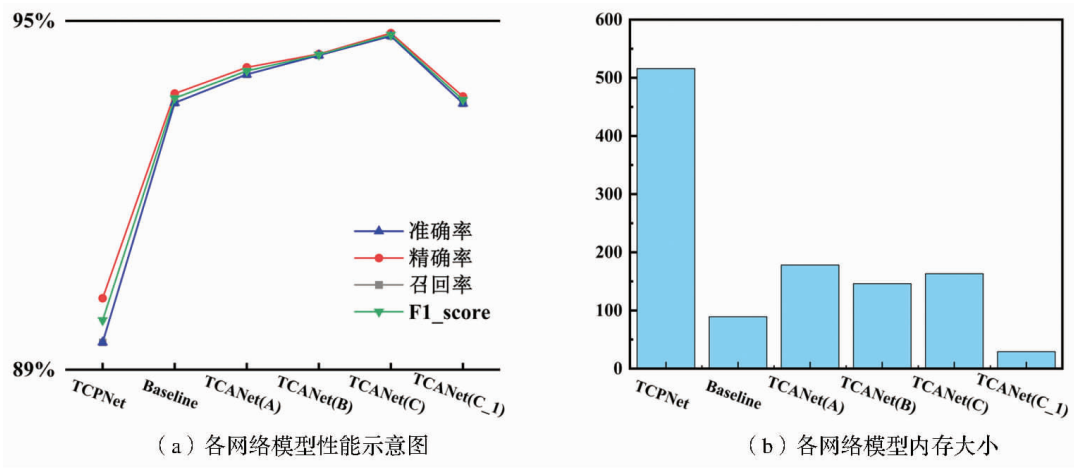


图 8　各网络模型训练结果

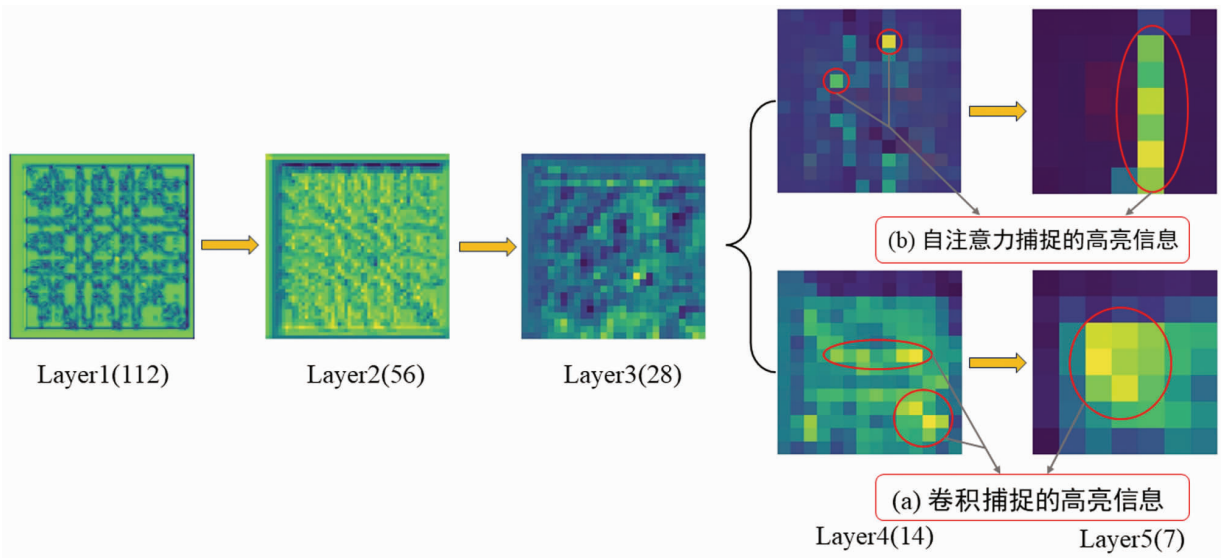


图 9　TCANet(C)模型权重可视化示意图(括号内为输入尺寸)

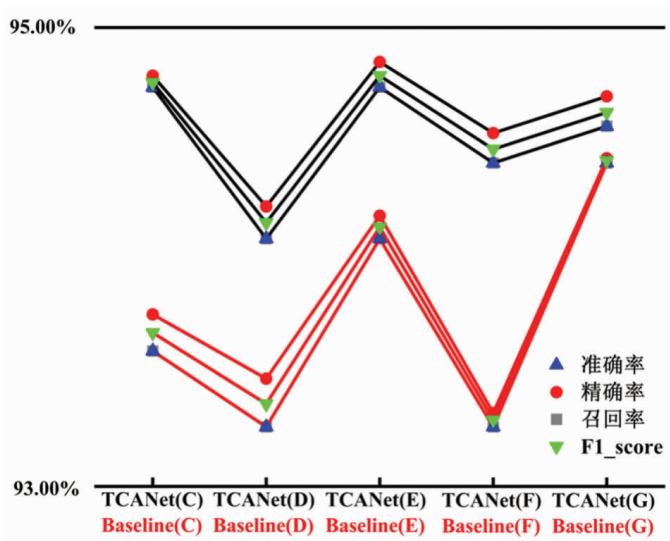
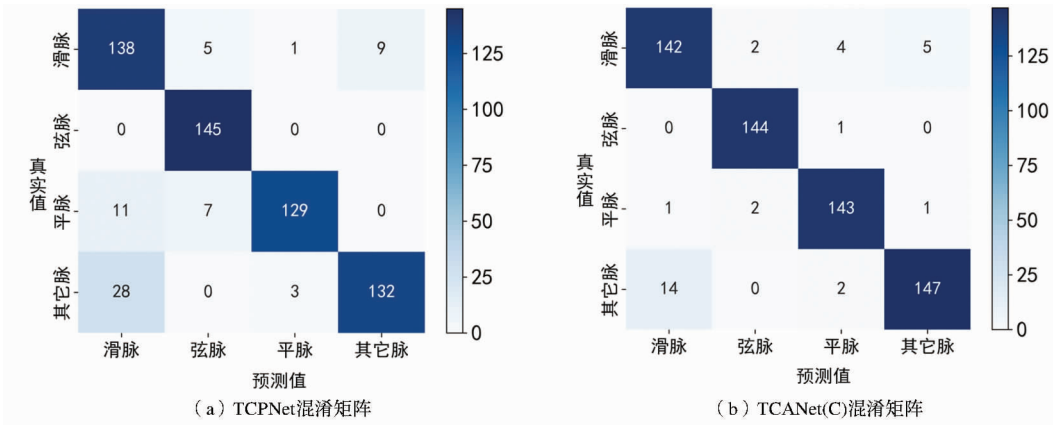


图 10　TCANet(D－G)网络模型训练结果



（a）TCPNet混淆矩阵　　（b）TCANet(C)混淆矩阵

图 11　TCPNet 和 TCANet(C)的混淆矩阵

基于 BDNF/Trkb/p38/JNK 信号通路研究电针抑制筋膜疼痛综合征模型大鼠肌肉细胞凋亡的机制

（正文见 44－50 页）

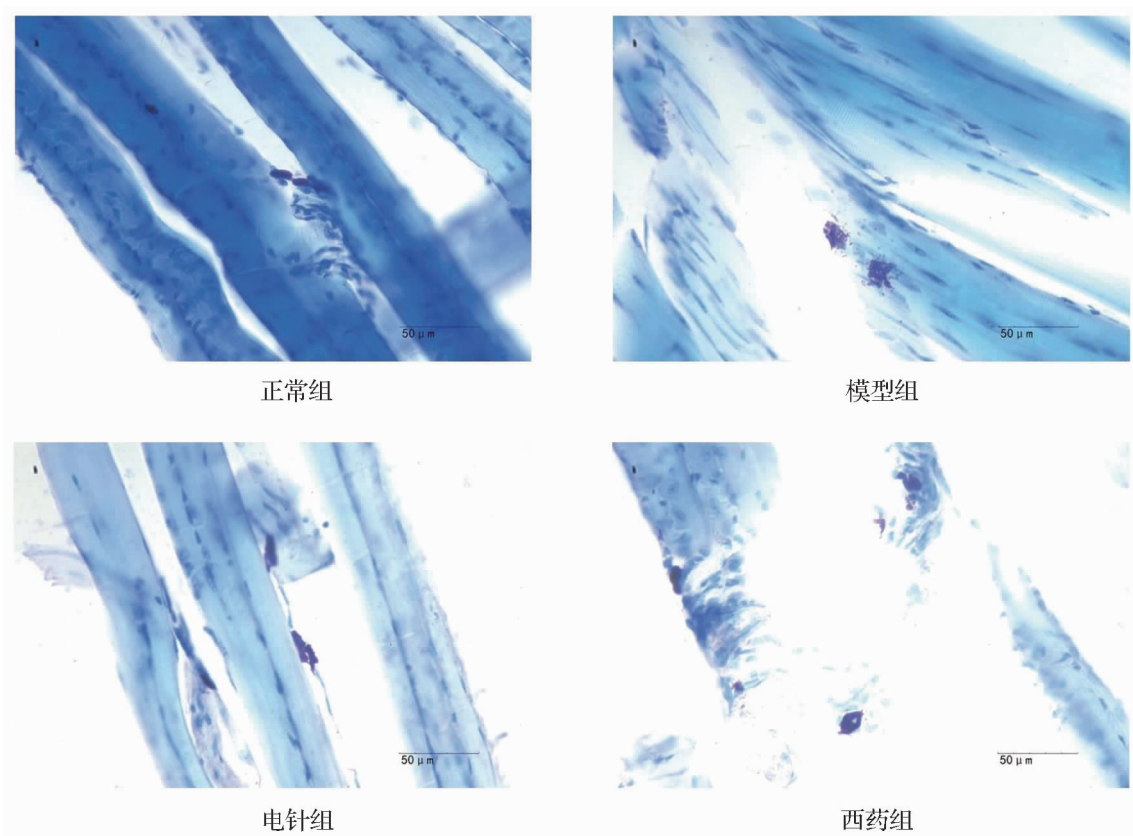


图 2　各组大鼠肌肉组织普鲁士蓝染色结果（$n=6$，倒置显微镜，×400）