

基于稀疏编码的弥散微循环模型参数估计神经网络

郑天舒¹, 颜国辉², 叶初阳³, 吴丹¹

(1. 浙江大学生物医学工程与仪器科学学院, 杭州 310027; 2. 浙江大学医学院附属妇产科医院, 杭州 310003; 3. 北京理工大学集成电路与电子学院, 北京 100081)

摘要: 弥散磁共振成像(Diffusion magnetic resonance imaging, dMRI)是一种重要的无创检测生物组织微观结构的医学成像工具,其中弥散微循环模型(Intravoxel incoherent motion, IVIM)是已被广泛用于分离组织水扩散和微血管血流运动的弥散磁共振成像模型。求解弥散微循环模型参数的传统方法依赖于从多 b 值扩散弥散磁共振成像数据(通常 ≥ 10 个 b 值)中拟合双指数模型,这需要一个相对较长的采集时间,对于体部弥散微循环模型成像是一个挑战。深度学习方法可以使用 q 空间数据的一个子集进行弥散磁共振成像模型参数估计,从而加速弥散磁共振成像的采集。然而,常见的基于卷积神经网络的深度学习与生物物理模型无关,因此,网络输出结果缺乏可解释性。本文将稀疏编码与深度学习相结合,提出了一种基于稀疏编码深度学习的弥散微循环模型参数估计方法。它利用了深度网络的表达优势,同时结合稀疏化表达的双指数模型来估计胎盘的弥散微循环模型参数,相比于其他算法,本文所拟的算法实现了更高的参数估计准确率和泛化能力。

关键词: 弥散微循环模型;深度学习;稀疏编码; q 空间加速;参数估计

中图分类号: TP391 **文献标志码:** A

Neural Network for Parameter Estimation of Intravoxel Incoherent Motion Based on Sparse Coding

ZHENG Tianshu¹, YAN Guohui², YE Chuyang³, WU Dan¹

(1. College of Biomedical Engineering & Instrument Science, Zhejiang University, Hangzhou 310027, China; 2. Department of Radiology, Women's Hospital, Zhejiang University School of Medicine, Hangzhou 310003, China; 3. School of Integrated Circuits and Electronics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Diffusion magnetic resonance imaging (dMRI) is an important medical imaging tool for the non-invasive detection of microstructures in biological tissues. Among others, intravoxel incoherent motion (IVIM) is a widely used dMRI model to separate diffusion and microvascular perfusion. Conventional methods to resolve IVIM parameters rely on fitting a biexponential model from multi- b -value dMRI data (typically ≥ 10 b -values), which requires a relatively long acquisition time. Such an acquisition is challenging for IVIM imaging of the body, such as placental IVIM, which is strongly influenced by both fetal and maternal motions. Deep learning models can accelerate the dMRI acquisition using a subset of the q -space data. However, common deep learning based on convolutional neural networks is not relevant to biophysical

基金项目: 国家科技部政府间国际科技创新合作重点专项(2018YFE0114600); 国家自然科学基金(61801424, 81971606, 82122032); 浙江省科技厅资助项目(202006140, 2022C03057)。

收稿日期: 2022-05-08; **修订日期:** 2022-07-06

models and, therefore, the outputs of the network are difficult to interpret. Here, this work combines sparse coding with deep learning to develop a sparse coding based deep neural network for the IVIM parameter estimation that takes advantage of the feature representation of deep networks while incorporating a potential bi-exponential model to estimate the microcirculation parameters of the placenta. Compared with other algorithms, the proposed algorithm demonstrates advantages in accuracy and generalizability.

Key words: intravoxel incoherent motion (IVIM); deep learning; sparse coding; q -space acceleration; parameter estimation

引 言

弥散磁共振成像(Diffusion magnetic resonance imaging, dMRI)是一种重要的医学成像工具,它基于水分子在生物组织中受限弥散作用,可建立弥散信号的生物物理模型,无创地重建生物组织内的微观结构^[1]。常用的表观弥散系数(Apparent diffusion coefficient, ADC)用一个单指数模型来计算,该单指数模型对脑卒中^[2]、肿瘤等病理变化敏感^[3-4],但不能特异性地反映微观层面病理变化。近30年来,领域内提出了多种复杂的生物物理模型来表征特定的微结构特性,如体素内不相干运动模型(Intravoxel incoherent motion, IVIM)^[5]、神经元定向弥散和密度成像(Neurite orientation dispersion and density imaging, NODDI)^[6]、用于肿瘤细胞术的血管、细胞外和限制性扩散模型(Vascular, extracellular and restricted diffusion for cytometry in tumors, VERDICT)^[7]、胞体和神经突密度成像(Soma and neurite density imaging, SANDI)^[8]等。

准确估计微结构模型参数对诊断具有重要意义。然而,大多数前沿的dMRI模型由多个房室组成,并且这些房室在数学上复杂且高度非线性。用传统的优化方法例如最小二乘法,对这些模型进行拟合,容易产生估计误差^[9]。此外,从数据获取的角度来看,先进的dMRI模型往往需要在 q 空间中获取多个 b 值和弥散梯度方向,这既耗时又容易受到运动伪影的影响。这对于运动的被试,例如腹部器官、胎儿和胎盘等,是一个不小的挑战。

为了减少这些估计误差和加速 q 空间采集,研究者们提出了许多方法。如Nedjati-Gilani等^[10]首先提出了基于随机森林的方法来对Kärger模型进行拟合;同一时间,Alexander等^[11]通过随机森林方法实现了在仅用单个 b 值的情况下,对NODDI模型和球面平均技术(Spherical mean technique, SMT)模型的参数估计。

随着深度学习技术的发展,深度学习的技术为dMRI模型拟合开辟了新的途径。Golkov等^[12]首先提出了基于 q 空间的深度学习方法,这是一种基于多层感知器(Multilayer perceptron, MLP)的方法,它利用 q 空间数据的一个子集来估计扩散峰度成像(Diffusion kurtosis imaging, DKI)参数。Barbieri等^[13]首次使用基于 q 空间的深度学习方法来对IVIM模型进行参数估计。然而,传统的基于 q 空间的深度学习方法与生物物理模型无关,因此很难被解释。在深层神经网络中引入领域知识作为先验信息被认为是提高网络性能和可解释性的有效途径。Ye^[14]首次将通过凸优化加速微结构成像(Accelerated microstructure imaging via convex optimization, AMICO)算法中字典构建的过程与深度学习结合,摒弃之前预先定义字典的方法,通过深度学习方法来得到字典,实现了对NODDI模型参数的准确估计。

由于之前的基于 q 空间的深度学习方法^[12]缺乏先验知识引导,受此基于稀疏先验的模型构建方法启发^[14],结合之前基于 q 空间的深度学习方法^[12]可以学习到降采样的 q 空间信号与模型参数映射关系的思想。本文将两者融合,提出了一种基于稀疏编码深度学习网络(Sparse coding deep neural network, SCDNN)的IVIM模型参数估计网络。该网络由稀疏表示编码器和参数映射解码器两部分构成,其中稀疏表示编码器和参数映射解码器,均通过数据驱动的方式学习得到。首先,假设IVIM模型所需要的 b 值具有稀疏性,通过稀疏表示编码器,低维空间中稠密采集的dMRI信号可以被转化为高维空间的稀疏离散信号;随后,通过参数映射解码器,稀疏离散信号可以与IVIM模型参数进行体素对体素的映射。

将这两部分结合,可以实现对IVIM模型在 q 空间的降采样,在采集时间更少的情况下获得近似于相同质量的图像信息,具有较高的准确度和精确性。本文还将所拟的网络和其他已有的dMRI参数估计网络在胎盘数据上进行了测试,发现基于稀疏编码深度学习网络的方法估计效果优于其他IVIM模型估计方法,并且更具备模型的解释性。

1 理 论

本节将会简要介绍IVIM模型、传统IVIM模型参数的估计方法以及如何通过稀疏表示的方法来估计IVIM模型的参数。

1.1 IVIM模型

IVIM模型由Le Bihan等^[5]提出,基于组织中和血液中水分子扩散率的不同建立双指数模型,可以同时获取组织(细胞、轴突等)中的水分子弥散信息和微循环(毛细血管、血小管)中的血流灌注信息。它已广泛应用于检测组织中的灌注情况,如大脑、肾脏、肝脏和胎盘等器官的灌注异常的检测^[15-17]。然而IVIM成像需要采集多 b 值(≥ 10 个 b 值)的扩散信号,采集较长,容易受到运动伪影的影响^[18]。体部器官随呼吸运动伪影较大,特别地,胎盘的成像不仅受到呼吸的影响还受到胎儿运动的影响。

常见的IVIM模型可以表示为

$$S_b = S_0 \left[(1-f)e^{-bD} + fe^{-bD^*} \right] \quad (1)$$

式中: b 为施加的弥散梯度场强度, S_b 为该 b 值下的信号值, S_0 为没有扩散加权时的信号值, f 为微循环的体积分, D 为组织水分子的弥散系数, D^* 为微循环血液中水分子的伪弥散系数。

1.2 IVIM模型的参数估计

常见的IVIM模型参数估计方法有两类,分别为基于非线性最小二乘法的参数估计和基于贝叶斯的参数估计。对于胎盘而言,基于非线性最小二乘法的参数估计先通过分段方法,通过相对高 b 值($> 200 \text{ s/mm}^2$)的数据,采用单指数模型估计 D 值以及组织中水分子组分对应的非扩散加权信号 S_0^{high} ;通过相对低 b 值($< 200 \text{ s/mm}^2$)的数据通过外插方法估计组织加血液对应非扩散加权信号 S_0^{low} , f 值可通过 $1 - S_0^{\text{high}}/S_0^{\text{low}}$ 进行估计; D^* 值可估计为 $D \times 10$ 得到 f 、 D 、 D^* 的估算值,再以此为初始条件和上下限条件,通过建立非线性最小二乘拟合方法来对其中的 f 、 D 、 D^* 来进行求解。贝叶斯估计则通过结合先验信息,通过贝叶斯公式,优化最大化后验概率的分布来求 f 、 D 、 D^* ^[19]。

1.3 IVIM模型的稀疏表示

稀疏表示可以被认为是一种表示学习方法,它已被普遍用于磁共振(Magnetic resonance imaging, MRI)的加速问题中^[20-21]。对于IVIM模型, q 空间的弥散信号可以用以下字典学习框架来表示。

$$y = \varphi x + \eta \quad (2)$$

式中: $y = S_b/S_0 \in \mathbb{R}^K$ 是一系列通过 S_0 归一化后的信号 S_b ,其中 K 为该样本中的弥散梯度个数; $\varphi \in \mathbb{R}^{K \times N}$ 是被定义的字典,其中 N 为稀疏系数向量的长度,在本文中,该字典通过神经网络学习得到; x 为与字典 φ 相关的稀疏系数向量; η 为与 x 对应的噪声向量。结合IVIM模型, φ 和 x 可被拓展为

$$\varphi = \left[\varphi^D, \varphi^{D^*} \right] \quad (3)$$

$$x = \left[x_{1-f}, x_f \right]^T \quad (4)$$

式中: φ^D 、 φ^{D^*} 分别与离散化的 D 和 D^* 相对应; x_{1-f} 对应于组织成分(D)的组成比例; x_f 为灌注成分(D^*)的组成比例。其中为了满足各组分之和为1的限制,稀疏系数向量 x 被归一化到 $[0, 1]$ 之间。

如果 φ 已经被预先定义好,则稀疏系数向量可以被通过求解如下的带有 l_1 正则化的目标函数得到。

$$\min_x \|y - \varphi x\|_2^2 + \beta \|x\|_1 \quad (5)$$

式中: β 为一个常数,用来控制稀疏系数向量 x 的稀疏性, β 越大时,稀疏系数向量 x 越稀疏。 l_1 正则化的优化可以通过许多算法来解决。在MRI领域,普遍使用迭代收缩阈值算法(Iterative shrinkage thresholding algorithm, ISTA)^[22-23]。优化该目标函数可以通过如下的迭代过程展开。

$$x^{n+1} = H_M[\varphi^H y + (I - \varphi^H \varphi)x^n] \quad (6)$$

式中: I 为单位矩阵; H_M 为非线性算子,可定义为

$$H_M(x_i) = \begin{cases} 0 & x_i < \lambda \\ x_i & x_i \geq \lambda \end{cases} \quad (7)$$

通过如上步骤,可以获得稀疏表示的信号。随后,可以通过如下的线性组合得到模型估计参数。

$$f = \sum x_{f_j} \quad (8)$$

$$D = \frac{\sum \varphi_j^D x_{f_j}}{\sum x_{f_j}} \quad (9)$$

$$D^* = \frac{\sum \varphi_j^{D^*} x_{1-f_j}}{\sum x_{1-f_j}} \quad (10)$$

2 方 法

本节将从如何构建基于IVIM模型的深度神经网络、训练所需样本以及训练方法3个方面来进行阐述。

2.1 网络构建

如前所述,基于IVIM模型的深度神经网络由稀疏表示编码器和参数映射解码器构成,具体方法如图1所示。

对于稀疏表示编码器,它将接受 q 空间降采样的输入信号,该输入信号通过信号提取层后输入字典层A后得到其对应的输出信号,随后将这一输出信号输入连续的迭代单元,迭代单元依照可以通过对式(6)字典构建的方法进行设计,通过迭代过程实现字典的构建,其中红色虚线所示的即对应迭代过程。

每个迭代单元中输入信号依次经过阈值层和字典层B,阈值层为一非线性算子,对应于式(6)中的 H_M ,字典层B则对数据进行组合,之后将字典层B输出的信号与

该迭代单元的输入信号通过残差连接相叠加,作为通过该迭代单元后的输出信号并作为下一个迭代单元的输入信号;第 n 个迭代单元中通过对信号的处理实现阈值迭代算法在IVIM模型中的通项表达式: $x^{n+1} = H_M[\varphi^H y + (I - \varphi^H \varphi)x^n]$,其中 φ^H 和 φ 对应于输入的线性层和迭代单元中线性层所学习到的权重, φ 为由离散化的组织水分子的弥散系数 D 和微循环血液中水分子的伪弥散系数 D^* 所构成的字典向量, I 是单位矩阵, H_M 为非线性算子, y 为输入信号, x^n 和 x^{n+1} 分别代表第 n 个迭代单元的输入信号和输出信号。如此进行反复迭代,得到通过所有迭代单元后的最终输出信号,将最终输出信号输入归一化层后,得到体积分数 f ,通过归一化后,使信号限制在0~1,满足实际生理状况;再将通过归一化层的输出分为等长的两部分,分别进行再次归一化后输入两个不同线性组合层进行信号组合,一个线性组合层输出由离散化的组织水分子的弥散系数 D 重新组合,另一个线性组合层输出由离散化的微循环血液中水分子的伪弥散系数 D^* 重新组合。

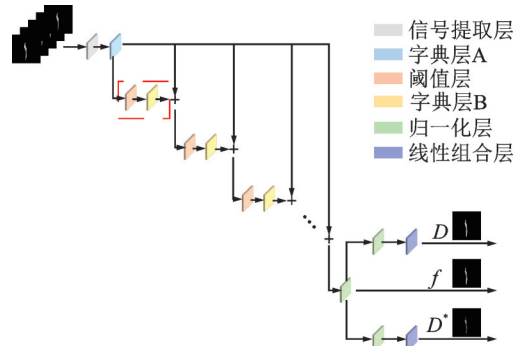


图1 基于IVIM模型的SCDNN结构示意图

Fig.1 Structure of IVIM model based SCDNN

2.2 数据及预处理

采用 29 名孕期在 13~37 周的被试数据中进行了数据集的构建。

2.2.1 序列参数

29 名磁共振扫描在通用电气 SIGNA HDXT 1.5 T 磁共振扫描仪上进行,采用扩散加权的平面回波成像序列从母体矢状位采集胎盘图像:回波时间(Echo time, TE)/重复时间(Repetition time, TR)= 76/3 000 ms,视野(Field of view, FOV)= 320 mm×320 mm,平面内分辨率为 1.25 mm×1.25 mm,层厚 4 mm,共 15 层,共采集 10 个 b 值的数据,分别为 0、10、20、50、80、100、150、200、300 和 500 s/mm²。

2.2.2 配 准

对 29 例被试中的每个胎盘数据进行自配准,以去除母体呼吸、胎儿运动导致的各个 b 值扩散加权图像间的位移。在配准过程中采用循环的配准方式操作 6~10 次之间不等。对每一位被试,将其各个 b 值的扩散加权图像进行平均,得到平均模板。然后,通过刚体变换和仿射变换将各个 b 值的扩散加权图像与平均模板进行比对配准。将配准之后得到的数据再次进行平均,得到第二次的平均模板,如此循环 6~10 次,选取其中位移最小的图像作为得到目标图像的配准结果。

2.2.3 金标准获取

将 2.2.2 节中配准好的图像,通过贝叶斯方法进行参数估计^[24],得到对应的 f, D, D^* 。由于通过贝叶斯方法得到的 f, D, D^* 存在因噪声造成的误差,因此将对应的 f, D, D^* 代入式(1)中,得到该组信号的无偏信号,并添加噪声。噪声的添加方式与文献[25]相同。

$$S_{\text{noisy}} = \sqrt{(S + \xi_1)^2 + (\xi_2)^2} \tag{11}$$

式中: S_{noisy} 为数据集的输入信号; S 为通过式(1)得到的信号; $\xi_1, \xi_2 \sim (0, \sigma^2), \sigma = S_0/\text{SNR}$,其中与文献[25]相同, $S_0=1$,训练数据 SNR=30。

2.3 训 练

将预处理好的 29 例孕周在 13~37 周的正常孕妇样本按照 6:4 的比例划分为训练集和测试集。其中训练集中有 15 例样本(324 016 个体素,其中与文献[12]相同,90% 用于训练,10% 用于验证),测试集中有 9 例样本(248 059 个体素)。本文选择使用 Adam 作为优化器,学习率设置为 1×10^{-4} ,总计 10 个历时,批次大小为 128。在网络训练的前 3 个历时中使用了余弦预热方法,学习率在 3 个历时后衰减。

3 实 验

对于 2.2 节中获取的数据集,采用基于 IVIM 模型的深度神经网络进行了估计,并与其他用于 dMRI 参数估计的方法进行了性能对比。同时,对基于 IVIM 模型的深度神经网络参数设置进行了分析。

3.1 性能分析

对基于 IVIM 模型的深度神经网络进行了性能分析。首先,对基于 IVIM 模型的深度神经网络的在训练集和验证集上的损失函数衰减曲线分别进行了观察,相关结果如图 2 所示。

3.1.1 收敛性分析

结合图 2,可以观察到,第 1 次迭代训练的

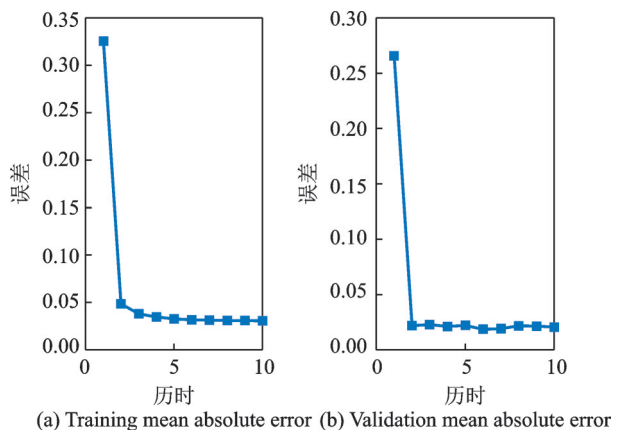


图 2 基于 SCDNN 的 IVIM 参数估计

Fig.2 Parameter estimation of IVIM model based on SCDNN

损失为 0.33 左右,验证集误差为 0.27 左右,说明模型刚开始训练时,损失较大,准确率较低。随着迭代周期增加,训练集误差和验证集误差在 5 个历时后趋于稳定,可以认为其收敛,此时得到的网络参数就是最终优化的网络参数指标。


3.1.2 结果分析

首先对于一例样本进行分析,结果如图 3 所示。对于该例样本,计算各参数网络输出的结果与其对应的金标准之间的决定系数(Coefficient of determination) R^2 。 R^2 可定义为


$$R^2 = 1 - \frac{\sum_i (y_i - f_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (12)$$

式中: y_i 为该参数的金标准; f_i 为该参数网络估计值; \bar{y} 为该参数金标准的平均值。对于 3 个参数 f 、 D 、 D^* ,其对应的 R^2 如图 3(a)所示,分别为 0.998 2、0.999 1、0.998 5。3 个参数的网络估计结果示意图及残差图(参数金标准-参数网络输出结果)如图 3(b)所示。由图 3(b)中的残差图可以看出, f 、 D 、 D^* 均可以达到较好的估计效果。

在全部测试集上比较了 5 种不同算法,包括两种传统优化方法(最小二乘法和贝叶斯估计)以及 3 种基于学习的方法(q 空间 MLP^[12]、IVIM 网络(IVIM-NET)^[13]和本文提出的基于 SCDNN 的 IVIM



(a) Correlation between the output of IVIM model based on SCDNN and gold standard



(b) Parameter maps and error maps (gold standard - output) of the SCDNN output

图 3 神经网络输出与金标准的相关性图及神经网络输出的参数图和误差图

Fig.3 Correlation between neural network output and gold standard and parameter maps and error maps of neural network output

参数估计),结果如表1所示。与传统优化方法最小二乘法和贝叶斯方法相比,基于学习的方法具有更高的估计精度。在基于学习的方法中,模型驱动方法的性能优于无先验信息的 q 空间的深度学习。

表1 比较5种方法在使用减少的 b 值 (20、50、150、300、500 s/mm²) 估计弥散微循环模型参数的均方误差
Table 1 Mean squared error comparison of five algorithms using a subset of b -values (20, 50, 150, 300, 500 s/mm²) for IVIM parameter estimation

算法	最小二乘法	贝叶斯估计	MLP	IVIM-NET	SCDNN
$f/10^{-5}$	540	120.0	6.80	25	0.72
$D/(10^{-3} \mu\text{m}^2 \cdot \text{ms}^{-1})$	230	2.2	0.51	280	0.31
$D^*/(10^{-1} \mu\text{m}^2 \cdot \text{ms}^{-1})$	198	2.2	3.80	130	0.18

3.2 泛化性分析

本节对基于 IVIM 模型的深度神经网络进行了泛化性分析。为了评估基于 IVIM 模型的深度神经网络的泛化性,在另一台通用电气 GE 750 W 的 3.0 T 磁共振扫描仪上通过相同的扫描序列参数进行了数据采集。采用扩散加权的平面回波成像序列从母体矢状位采集胎盘图像:TE/TR = 76/3 000 ms, FOV = 320 mm × 320 mm,平面内分辨率为 1.25 mm × 1.25 mm,层厚 4 mm,共 15 层,共采集 10 个 b 值数据,分别为 0、10、20、50、80、100、150、200、300 和 500 s/mm²。与 3.1.2 节相同,比较了所有的 5 种算法,结果如表 2 所示。从表 2 中可以观察到,在同一品牌的 3.0 T 数据上进行测试,发现其他基于学习的方法有不同程度上的误差升高,其中,无监督 IVIM-NET 误差升高最多,本文方法具有最高的准确度,证明本文方法具有更好的泛化性。

表2 泛化性测试比较5种方法在使用减少的 b 值 (20、50、150、300、500 s/mm²) 在另一个中心采集到的数据估计弥散微循环模型参数的均方误差

Table 2 Generalizability test on data acquired from another center, based on the mean squared error of five algorithms using a subset of b -values (20, 50, 150, 300, 500 s/mm²) for IVIM parameter estimation

算法	最小二乘法	贝叶斯估计	MLP	IVIM-NET	SCDNN
$f/10^{-4}$	320	30	29	196.0	4.40
$D/(10^{-4} \mu\text{m}^2 \cdot \text{ms}^{-1})$	97	21	12	9 080.0	0.72
$D^*/(10^{-1} \mu\text{m}^2 \cdot \text{ms}^{-1})$	973	45	34	200.2	8.40

3.3 网络参数分析

本节对 SCDNN 的参数设置进行了分析。首先,对于不同 b 值的选取进行了实验,之后对于所建立字典大小进行了实验。

3.3.1 b 值组合分析

本节对于如何选取 IVIM 模型训练时所需要的 b 值数量和 b 值组合进行了研究。在之前的实验中,选取了减少到 5 的 b 值数量 (20、50、150、300、500 s/mm²) 来进行估计。在这里对 5 个 b 值数量的不同组合进行了估计,同时也对不同数量的 b 值选取进行了估计。其中对数量为 5 个, b 值大小为 20~500 s/mm² 的 5 种组合进行了估计,结果如表 3 所示。

结合表 3,可以发现,在 b 值数量为 3 时,参数 f 、 D 、 D^* 的估计结果与 b 值数量为 5 或 7 时相比较差。当

表3 不同数量及不同 b 值组合得到的 IVIM 参数估计值与金标准的均方误差Table 3 Mean squared errors of IVIM parameter estimation using different numbers of b -values and different combinations of b -values

组合方式	$f/10^{-4}$	$D/(10^{-4} \mu\text{m}^2 \cdot \text{ms}^{-1})$	$D^*/(10^{-2} \mu\text{m}^2 \cdot \text{ms}^{-1})$
3个 b 值的组合 (20, 150, 500) s/mm ²	2.000	37.0	14.0
5个 b 值的组合 1 (20, 50, 150, 300, 500) s/mm ²	0.072	3.1	1.8
5个 b 值的组合 2 (20, 50, 150, 200, 500) s/mm ²	7.100	2.1	6.2
5个 b 值的组合 3 (20, 50, 200, 300, 500) s/mm ²	0.400	2.1	9.0
5个 b 值的组合 4 (20, 100, 150, 300, 500) s/mm ²	0.270	9.0	2.2
5个 b 值的组合 5 (20, 80, 150, 300, 500) s/mm ²	0.190	3.2	2.7
7个 b 值的组合 (20, 50, 100, 150, 200, 300, 500) s/mm ²	0.100	3.2	2.8

b 值数量为 7 时, 参数 f 、 D 、 D^* 的估计结果与 b 值数量为 5 时最优结果总体误差相接近, 且并不优于 b 值数量为 5 时的结果。因此, 在最终的 b 值选取上选择 5 个 b 值组合为 20、50、150、300、500 s/mm² 的降采样方式。

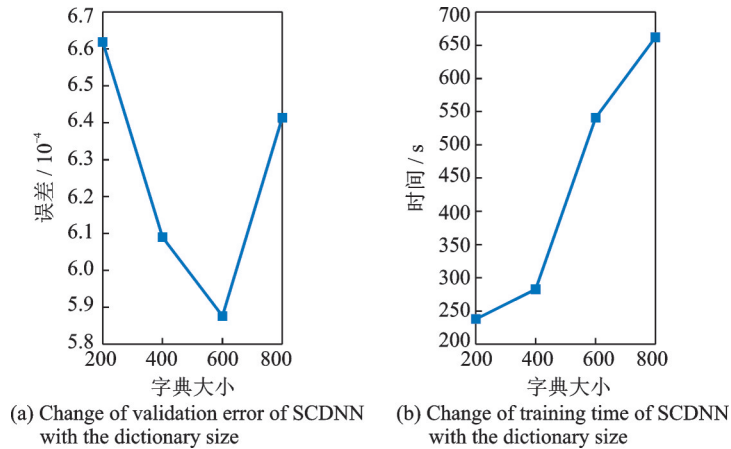


图4 SCDNN 随字典大小变化验证集误差及训练时间示意图

Fig.4 Changes of the validation error and training time of SCDNN with dictionary size

3.3.2 字典大小分析

本节对字典大小为 200~600 的结果进行了分析, 结果如图 4 所示。从图 4 可以观察到, 随着字典大小从 200 到 600 的增加, 验证集均方误差逐渐降低, 字典大小从 600 增加 800, 验证集误差升高; 并且随字典大小的增加, 训练时间显著增长。因此选择字典大小为 600。

4 结束语

本文通过提出了一种基于稀疏编码深度学习网络的弥散微循环模型参数估计方法来估计 IVIM 模型参数 f 、 D 、 D^* , 该方法借助深度学习的方法, 结合弥散微循环模型的物理原理, 可以通过少数 b 值的 q 空间信息拟合, 有效缩短了采集数据所消耗的时间, 并且能够比现有的参数估计方法有更小的误差, 同时从多中心比较实验来看, 该算法具有良好的泛化性能。

参考文献:

- [1] MORI S, ZHANG J. Principles of diffusion tensor imaging and its applications to basic neuroscience research[J]. *Neuron*, 2006, 51(5): 527-539.
- [2] 霍晓川, 高峰. 急性缺血性卒中血管内治疗中国指南 2018[J]. *中国卒中杂志*, 2018, 13(7): 706-729.
HUO Xiaochuan, GAO Feng. Chinese guidelines for intravascular therapy of acute ischemic stroke 2018[J]. *Chinese Journal of Stroke*, 2018, 13(7):706-729.
- [3] LE BIHAN D, MANGIN J F, POUPON C, et al. Diffusion tensor imaging: Concepts and applications[J]. *Journal of Magnetic Resonance Imaging*, 2001, 13(4): 534-546.
- [4] 赵斌, 蔡世峰, 高佩虹, 等. MR 扩散加权成像鉴别乳腺良恶性病变的研究[J]. *中华放射学杂志*, 2005, 39(5): 497-500.
ZHAO Bin, CAI Shifeng, GAO Peihong, et al. Study on differentiation of benign and malignant breast lesions by MR diffusion weighted imaging[J]. *Chinese Journal of Radiology*, 2005, 39 (5): 497-500.
- [5] LE BIHAN D, BRETON E, LALLEMAND D, et al. Separation of diffusion and perfusion in intravoxel incoherent motion MR imaging[J]. *Radiology*, 1988, 168(2): 497-505.
- [6] ZHANG H, SCHNEIDER T, WHEELER-KINGSHOTT C A, et al. NODDI: Practical in vivo neurite orientation dispersion and density imaging of the human brain[J]. *NeuroImage*, 2012, 61(4): 1000-1016.
- [7] PANAGIOTAKI E, WALKER-SAMUEL S, SIOW B, et al. Noninvasive quantification of solid tumor microstructure using Verdict MRI[J]. *Cancer Research*, 2014, 74(7): 1902-1912.
- [8] PALOMBO M, IANUS A, GUERRERI M, et al. SANDI: A compartment-based model for non-invasive apparent soma and neurite imaging by diffusion MRI[J]. *NeuroImage*, 2020, 215: 116835.
- [9] ARUN K S, HUANG T S, BLOSTEIN S D. Least-squares fitting of two 3-D point sets[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1987, 9(5): 699-700.
- [10] NEDJATI-GILANI G L, SCHNEIDER T, HALL M G, et al. Machine learning based compartment models with permeability for white matter microstructure imaging[J]. *NeuroImage*, 2017, 150: 119-135.
- [11] ALEXANDER D C, ZIKIC D, GHOSH A, et al. Image quality transfer and applications in diffusion MRI[J]. *NeuroImage*, 2017, 152: 283-298.
- [12] GOLKOV V, DOSOVITSKIY A, SPERL J I, et al. q-space deep learning: Twelve-fold shorter and model-free diffusion MRI scans[J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1344-1351.
- [13] BARBIERI S, GURNEY-CHAMPION O J, KLAASSEN R, et al. Deep learning how to fit an intravoxel incoherent motion model to diffusion-weighted MRI[J]. *Magnetic Resonance in Medicine*, 2020, 83(1): 312-321.
- [14] YE C. Estimation of tissue microstructure using a deep network inspired by a sparse reconstruction framework[C]//*Proceedings of International Conference on Information Processing in Medical Imaging*. [S.l.]: Springer, 2017: 466-477.
- [15] 宋琼, 马静, 饶圣祥, 等. MR 全肝 IVIM 灌注分析对肝癌微循环功能状态的影像生物学标记物的评价研究[J]. *影像诊断与介入放射学*, 2013(3): 181-184.
SONG Qiong, MA Jing, Rao Shengxiang, et al. Evaluation of imaging biomarkers of microcirculation function of liver cancer by MR whole liver IVIM perfusion analysis[J]. *Image Diagnosis and Interventional Radiology*, 2013 (3): 181-184.
- [16] 尹茵, 甘洁. 体素内不相干运动成像[J]. *中国临床医学影像杂志*, 2013, 24(5): 353-356.

- YIN Yin, GAN Jie. Incoherent motion imaging in voxels[J]. Chinese Journal of Clinical Medical Imaging, 2013, 24 (5): 353-356.
- [17] 曲丽洁, 周建军, 丁玉芹, 等. 磁共振体素内不相干运动成像和扩散峰度成像在正常肾脏成像中的初步研究[J]. 放射学实践, 2016, 31(10): 908-913.
QU Lijie, ZHOU Jianjun, DING Yuqin, et al. Preliminary study of magnetic resonance voxel incoherent motion imaging and diffusion kurtosis imaging in normal kidney imaging[J]. Radiology Practice, 2016, 31 (10): 908-913.
- [18] 邢春华, 陈宏伟, 崔兴宇. 腹部 IVIM-DWI 应用研究及进展[J]. 国际医学放射学杂志, 2015, 38(4): 335-338.
XING Chunhua, CHEN Hongwei, CUI Xingyu. Research application and advances of IVIM-DWI in abdomen[J]. International Journal of Medical Radiology, 2015, 38(4): 335-338..
- [19] GUSTAFSSON O, MONTELIUS M, STARCK G, et al. Impact of prior distributions and central tendency measures on Bayesian intravoxel incoherent motion model fitting[J]. Magnetic Resonance in Medicine, 2018, 79(3): 1674-1683.
- [20] DADUCCI A, CANALES-RODRÍGUEZ E J, ZHANG H, et al. NeuroImage accelerated microstructure imaging via convex optimization (AMICO) from diffusion MRI data[J]. NeuroImage, 2015, 105: 32-44.
- [21] SCHWAB E, VIDAL R, CHARON N. Spatial-angular sparse coding for HARDI[C]//Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. [S.l.]: Springer, 2016: 475-483.
- [22] GUERQUIN-KERN M, HABERLIN M, PRUESSMANN K P, et al. A fast wavelet-based reconstruction method for magnetic resonance imaging[J]. IEEE Transactions on Medical Imaging, 2011, 30(9): 1649-1660.
- [23] LIU Y, ZHAN Z, CAI J F, et al. Projected iterative soft-thresholding algorithm for tight frames in compressed sensing magnetic resonance imaging[J]. IEEE Transactions on Medical Imaging, 2016, 35(9): 2130-2140.
- [24] JALNEFJORD O, ANDERSSON M, MONTELIUS M, et al. Comparison of methods for estimation of the intravoxel incoherent motion (IVIM) diffusion coefficient (D) and perfusion fraction (f)[J]. Magnetic Resonance Materials in Physics, Biology and Medicine, 2018, 31(6): 715-723.
- [25] DADUCCI A, VILLE D VAN D E, PHILIPPE T J, et al. Sparse regularization for fiber ODF reconstruction: From the suboptimality of “2” and “1” priors to “0”[J]. Medical Image Analysis, 2014, 18(6): 820-833.

作者简介:



郑天舒(1996-),男,博士研究生,研究方向:人工智能与弥散磁共振,E-mail: zhengtianshu@zju.edu.cn。



颜国辉(1987-),男,硕士,主管技师,研究方向:妇产科学。



叶初阳(1985-),男,副教授,博士生导师,研究方向:医学图像处理。



吴丹(1985-),通信作者,女,教授,博士生导师,研究方向:磁共振成像,E-mail: danwu.bme@zju.edu.cn。

(编辑:王静)