

白细胞图像超分辨率重建研究

王伟 胡涛 李欣蔚 沈思婉 姜小明 刘峻源

重庆邮电大学生物医学工程研究中心 重庆 400065

重庆邮电大学重庆市医用电子与信息技术工程研究中心 重庆 400065

(wangw@cqupt.edu.cn)



摘要 近年来,计算机视觉已成为各类学科领域研究的重点,逐渐被应用于各类科研场景。医务工作者在临床上做血常规检验时,经常会采用血细胞图像分析系统对镜下白细胞图像进行自动计数与分类。其中,白细胞图像质量影响着血细胞分析系统计数分类的效果。针对镜下白细胞图像细节模糊的问题,文中尝试引入超分辨率方法对图片进行优化,以达到使白细胞图像更清晰的目的。所提出的方法在现有生成对抗网络的超分辨率方法(Super-Resolution Generative Adversarial Network, SRGAN)的基础上,设计引入嵌套型残差密集块(Residual-in-Residual Dense Block, RRDB)来改进网络结构,并对原有标准残差块中的批量规范化层进行删减,以提升网络性能,另外还对判别器的损失函数进行了改进。实验结果表明,该方法(SRGAN+)与3种插值法以及4种基于学习的超分辨率方法相比,在提高分辨率的同时,获得了图片细节更丰富、人眼视觉更优的图像。与SRGAN方法相比,改进算法在峰值信噪比(Peak Signal-to-noise Ratio, PSNR)和结构相似度(Structural SIMilarity, SSIM)上分别有1.008 dB和1.07%的提高。

关键词: 白细胞图像;超分辨率;生成对抗网络;嵌套型残差密集块

中图分类号 TP391

Study on Super-resolution Image Reconstruction of Leukocytes

WANG Wei, HU Tao, LI Xin-wei, SHEN Si-wan, JIANG Xiao-ming and LIU Jun-yuan

Research Center of Biomedical Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Chongqing Engineering Research Center of Medical Electronics and Information Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract In recent years, computer vision has become the focus of research in various disciplines and has been gradually applied to numerous scientific research scenarios. Medical workers often use blood cell image analysis systems to automatically count and classify white blood cell images when performing blood routine tests in the clinic. Among them, the white blood cell image quality affects the counting classification effect of the blood cell analysis system. This paper focuses on the problem of blurred details of white blood cell images under the microscope and attempts to introduce a super-resolution method to solve the problem. This method introduces a Residual-in-Residual Dense Block (RRDB) based on the Super-Resolution Generative Adversarial Network (SRGAN) to improve the network structure and remove the batch normalization layer in the standard residual block. The network performance is improved and the loss function of the discriminator is improved. Experimental results show that, compared with 3 interpolation methods and 4 learning-based super-resolution methods, the proposed method (SRGAN+) improves the resolution while obtaining images with richer textures and more realistic visuals. Compared with the SRGAN method, the proposed algorithm has a 1.008 dB improvement in peak signal-to-noise ratio (PSNR) and 1.07% improvement in Structural SIMilarity (SSIM).

Keywords Leukocyte image, Super-resolution, Generative adversarial network, Residual-in-Residual dense block

1 引言

图像的超分辨率技术可以将低分辨率图像转化为符合需

要的高分辨率图像。超分辨率技术的应用较为多元化,其在遥感图像^[1]、视频监控优化^[2]以及医学影像诊断^[3]方面都有着广泛的应用。

到稿日期:2020-01-15 返修日期:2020-05-20 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61801069);重庆市教育委员会科学技术研究项目(KJQN201800622)

This work was supported by the National Natural Science Foundation of China(61801069) and Chongqing Education Commission Science and Technology Research Project(KJQN201800622).

通信作者:李欣蔚(lixinwei@cqupt.edu.cn)

插值、重建和基于学习的方法是研究超分辨率(Super-resolution, SR)重建的主流思想。其中,插值的方法常使用最近邻插值(Nearest Neighbor Interpolation, NNI)^[4]和双三次插值(Bicubic)^[5]。该类型方法在计算时通常会默认一个前提,即在任意图像区域内像素灰度值具有连续变化的性质,超分辨率的实现则是依靠图像自身区域像素点的灰度值来计算目标像素点的灰度值。当图像纹理较为丰富时,该类算法得到的生成图像容易产生棋盘效应。基于重建的超分辨率技术常见的方法包括凸集投影法^[6]、迭代反投影法^[7]以及最大后验概率方法^[8]。此类方法假设根据低质量图像可以估计出原高质量图像,其生成的图片虽然在视觉效果上解决了插值方法造成的图像棋盘效应的问题,但当所需目标图像的分辨率较高或者原图像过小时,其重建效果不佳。

近年来,随着基于深度学习的超分辨率方法的相关比赛的增加,越来越多的研究者们开始使用学习的方法对超分辨率及相关问题进行探索。Dong等^[9]于2014年提出了结合卷积神经网络的超分辨率算法模型(Convolutional Neural Network for Image Super-Resolution, SRCNN),提出根据卷积神经网络结构依次对图像块信息进行充分提取和表达,进而完成非线性映射和提高分辨率的操作。基于卷积神经网络的方法重建出的图像与基于插值和重建方法获得的图像相比,图像效果有很大的提升。Dong等^[10]于2016年在原来算法的基础上提出了FSRCNN(Fast SRCNN)方法,将卷积网络结构扩展为8层,并在网络最后使用反卷积对低分辨率图像进行采样。使用此方法得到的图像在效果上明显优于使用SRCNN进行处理的图像。Kim等^[11]设计了一种以深度递归神经网络(Deeply-Recursive Convolutional Network, DRCN)为框架的超分辨率算法,此算法侧重于增大各层卷积核的尺寸,从而获取更多关于目标像素的周边信息。另外,该方法还引入递归神经网络,使得网络更为简化,生成的图像质量较优。Ledig等^[12]于2017年引入生成对抗模型的思想,其提出的算法以低质量图片作为输入,经过生成器训练,使得模型能够拟合高质量图片样本的概率分布,同时使用鉴别器鉴别生成器所生成图片的真伪,从而提高图像分辨率。该算法运用生成对抗的思想,所提出的方法与他学习方法相比,生成的图片质量更优。

图像的超分辨率即是把图像从低分辨率(Low Resolution, LR)复原为高分辨率(High Resolution, HR)的问题。本文使用Bicubic插值方法模拟高分辨率图像的退化过程。鉴于深度学习超分辨率方法生成的图像质量高、效果好,本文在Ledig等^[12]原有工作的基础上对网络结构进行优化,在去掉批量规范化层、加深网络等方面进行调整,提出了基于嵌套型残差密集块的生成对抗网络(SRGAN+)算法,以实现白细胞图像的超分辨率重建工作。

2 理论介绍

2.1 生成对抗网络

Goodfellow等^[13]于2014年根据博弈论中著名的零和博弈思想设计了生成对抗网络框架(Generative Adversarial Network, GAN)。该框架近几年在图像处理领域取得了很多优秀的业绩^[14-16],其主要通过多次训练样本来学习样本的概

率分布。GAN的框架包含两个模型的相互对抗,即生成器(Generative model, G)不断模拟样本分布生成图片,鉴别器(Discriminative model, D)区分生成图片的真假,直至鉴别器无法辨别真实图片与生成图片为止。这两个模型各自进行训练, D对G生成的图片进行真假判断,二者在目标函数的约束下得到最优结果。GAN的结构示意图如图1所示。




图1 GAN的基本结构

Fig. 1 Structure diagram of GAN

2.2 残差和跳跃连接

传统的卷积神经网络模型为了提高分类或预测等任务的准确率,往往会通过卷积层线性叠加的方式来对网络进行加深。但研究人员经过多次实验发现,如果网络中的卷积层过多,训练时就容易出现深层网络梯度弥散(Vanishing)的问题。为了避免这种现象的发生,研究者们引入了残差网络予以解决。残差网络(Residual Network, ResNet)由He等^[17]于2015年提出,残差密集块(Residual Dense Block, RDB)的基本结构如图2所示。




图2 基本残差块

Fig. 2 Basic residual block

其中, $C(x)$ 为网络中通过堆叠的非线性层学习得到的残差,图中以 x 作为输入值, C 为映射函数。由图2可知,在残差块的第三层中,将 $C(x)$ 与 x 结合为所需的映射 $H(x)$ 后,再进行激活输出。如果在第三层输出值激活前加入 x ,那么我们称这条路径为跳跃连接(skip connection)。由于该连接的存在,网络对 $H(x)$ 的学习转为对 $C(x)$ 的学习。一般来说,残差网络中的残差块结构叠加,保证了更深层的网络比浅层的网络包含更多的图像信息,这样可较好地避免深层网络出现退化问题,进一步提高网络性能。

残差结构的特点可以让我们设计更深的网络,以便提取图像的高级抽象特征,进而得到更好的网络模型。鉴于近年来残差网络结构在图像处理上的效果较好,本文将使用残差块对模型的结构进行改进。

3 基于SRGAN的改进算法

3.1 改进思路

本文在SRGAN的基础上对GAN网络进行改进,使GAN框架在白细胞图像的超分辨率处理上有更好的效果。本文借鉴文献^[18]提出的嵌套型残差密集块的思想,用嵌套型残差密集块替换原始生成器中的残差块。该嵌套型残差密集块的密集连接有助于网络容量的提升,采用多层的残差网

络,用于学习图片不同层级的特征。同时,为了保证训练过程的稳定性和一致性,本方法将取消 ResNet 中的 BN(Batch Normalization)层,这不仅有助于提高网络的泛化能力,同时还降低了计算复杂度和内存占用^[19]。另外,深层次的网络能够建立高维特征的映射,进而提高网络对图片特征提取的精确性^[20],因此,本文设计了较深的残差网络结构。下文中,我们将首先描述改进的生成器的网络结构,然后从判别器和损失函数两个方面描述所使用的方法。

3.2 生成器

如图 3 所示,本网络生成器的输入为经 Bicubic 进行 4 倍降采样后的低分辨率白细胞图片,设计的生成器网络结构大部分由如图 4 所示的嵌套型残差块构成,1 个 RRDB 由 3 个 RDB 所构成。




图 3 生成器网络

Fig. 3 Generator network




图 5 判别器网络结构

Fig. 5 Discriminator network structure

3.4 Loss 函数

Loss 函数用来指导网络训练。本文中关于生成器 Loss 函数的设计,主要由感知损失(L_{percep})、对抗损失(L_G^R)以及 Pixel-wise(L_2)损失 3 部分构成。将生成器的总损失函数定义为:

$$L_G = \alpha L_{percep} + \lambda L_G^R + \eta L_2 \quad (1)$$

对于 α, λ 及 η ,我们先凭经验值选择了一定的范围,然后经过多次微调实验得到,当 $\alpha = 0.8 (\pm 0.05)$, $\lambda = 1 \times 10^{-2}$, $\eta = 2 \times 10^{-3}$ 时,图片整体生成的质量较好,当 λ 和 η 取其他值时,生成的图片容易失真变形。其中, L_{percep} 是基于 $L1$ 的损失函数,本研究将该损失定义在一个预训练 VGG16 网络的激活层,可使该网络更偏向于纹理细节特征的提取。生成器的对抗损失 L_G^R 及 L_2 的定义如式(2)~式(3)所示:

$$L_G^R = -\mathbb{E}_{x_r} [\log(1 - D_{Rd}(x_r, x_f))] - \mathbb{E}_{x_f} [\log(D_{Rd}(x_f, x_r))] \quad (2)$$

$$L_2 = l_{MSE}^{SR} = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H (I_{x,y}^{HR} - G_{\theta_c}(I_{x,y}^{LR}))^2 \quad (3)$$

式(2)中的 L_G^R 用于表示生成器的对抗损失函数, x_r 及 x_f 分别对应输入的真实图片以及生成网络生成的图片。相应地, $D_{Rd}(x_r, x_f)$ 是预测真实图像 x_r 与生成图片 x_f 显得更真实的概率, $D_{Rd}(x_f, x_r)$ 是预测生成图片 x_f 与真实图像 x_r 显得更真实的概率。式(3)中的 L_2 表示 $I_{x,y}^{HR}$ 与生成图像 $G_{\theta_c}(I_{x,y}^{LR})$ 像素之间的损失, I^{LR} 和 $I_{x,y}^{HR}$ 分别表示低分辨率图像及

由图 3 可知,残差密集块通过连接卷积层来提取丰富的局部信息。同时,1 个 RDB 的输出直接连接到当前 RDB 的所有层,进而融合更有效的局部特征,稳定网络的训练,提升网络的性能。





图 4 嵌套型残差密集块

Fig. 4 Residual in residual dense block(RRDB)

3.3 判别器

本文中的判别器网络用于区分真实的白细胞图片和生成的白细胞图片。网络结构部分有 8 个卷积层,采用隔层 4×4 尺寸的卷积核增大局部感受野。如图 5 所示,对应卷积层通道的数量从第二层开始,相应每层的通道数以 2 倍逐渐增加,直到第 7 层的 512 个。同时,将每层的卷积操作都作为下一层的输入进行训练;接着对输出特征进行线性变换,然后用 LReLU 对特征进行激活。判别器的网络结构如图 5 所示。



高分辨率图像。 W 和 H 两个参数在公式中分别代表图片的宽和高, θ_c 表示所有层的权重与偏置参数值。本文借鉴 Relativistic GAN^[21] 中的方法对判别器进行了改进,使判别器可以估计一幅图像是否比另一幅图像更真实的概率。判别器的损失函数定义为:

$$L_D^R = -\mathbb{E}_{x_r} [\log(D_{Rd}(x_r, x_f))] - \mathbb{E}_{x_f} [\log(1 - D_{Rd}(x_f, x_r))] \quad (4)$$

判别器的对抗损失的输入包括 x_r 及 x_f , x_r 代表真实的白细胞图像, $x_f = G(x_r)$ 代表低分辨率图像经生成器得到的图像。式(4)中求期望的操作是通过 mini-batch 中的所有数据求均值得到的。其中,真实数据与生成数据之间的梯度决定了对抗损失对判别器优化的过程。

3.5 训练过程

首先采用 mini-batch 的方式进行训练,mini-batch 的数量预设为 16。训练时,将每个 mini-batch 的每幅真实高质量图片裁剪为多个 240×240 像素大小的子图片,用 Bicubic 方法对 240×240 的白细胞图片下采样 4 倍,得到对应的 60×60 像素的低质量白细胞图像。然后,将以上操作得到的高质量图片和对应的低质量图片分别作为输入,加载到判别器和生成器网络中进行迭代训练。另外,使用 Adam 优化网络参数。为保证训练能够较好地符合预期效果,我们将初始学习率(lr)设为 1×10^{-4} ,迭代总次数初始化为 400 000 次,迭代训练每隔

50000 次自动将学习率递减为原来的一半,以优化训练过程。

4 实验仿真与结果分析

本实验使用的是 kaggle 以及 CellaVision 的白细胞开源数据集,并从中挑选了清晰度高、纹理丰富的 863 张高质量的图片,其中,763 张用于训练,100 张作为测试集。本实验的硬件平台为一台搭载 2 块 NVIDIA Tesla V100 的 Intel Xeon 服务器。实验的软件平台是 64 位 Ubuntu 14.04.5 LTS 操作系统,CUDA Toolkit 10.0,Python3.7。




图 6 各超分辨率方法效果的对比

Fig. 6 Results comparison of various super-resolution methods

4.1 图像质量评价参考指标

图像压缩、修复方面常使用峰值信噪比、MSE (Mean Squared Error)和结构相似性^[23]等客观度量指标来评价图像质量的优劣。因此,我们将 PSNR,SSIM 及 MSE 作为图像质量对比的主要参考指标。另外,效率表征着算法处理图像的快慢。因此,算法处理每张图片的平均耗时也作为参考指标对本文算法进行评价。

4.2 客观效果

交叉验证(Cross Validation)是统计学中常用来分析网络精度的方法。我们利用交叉验证分析改进后的网络性能。将原始样本(Train 和 Test 数据集中的白细胞图像)以随机的方式划分为 10 等份(Data1, Data2, ..., Data10),其中,9 份白

细胞图像用于训练网络,其余的白细胞图像样本作为测试集。重复这个过程,得到 10 份不同的白细胞数据集,训练后得到 10 个不同的训练模型。本文取这些模型对测试集的平均 PSNR, MSE 及 SSIM 值进行对比,结果如表 1 所列。

为了验证本文算法模型的有效性,我们特别选取了 3 种基于插值的以及 4 种基于深度学习的超分辨率方法进行对比。插值方法为 NN, Bilinear 及 Bicubic, 4 种基于学习的方法分别为 SRCNN, FSRCNN, SubPixel CNN^[22]以及 SRGAN。以上算法均统一使用本实验的软硬件平台进行仿真。此外,其他基于学习的模型的训练参数均与本实验设置的参数相同。

我们选取 2 幅有代表意义的白细胞图片进行对比测试,用以验证各算法的处理效果。实验结果如图 6 所示。

根据交叉验证的原理,系统的性能由最终所有模型的表现均值来评价,即本文所改进模型的 PSNR, MSE, SSIM 分别为 35.89, 7.20, 0.9483。本文还基于各方法对整个测试集进行计算,取平均值得出整个数据集的 PSNR, SSIM, 并记录各算法的耗时,以实际数据值作为评价各算法优劣的参考。测试集数据平均的 MSE, PSNR, SSIM 和各算法处理一张图片的平均耗时如表 2 所列。

表 1 不同模型在交叉验证法下的 PSNR, MSE, SSIM 表现(交叉验证)

Table 1 PSNR, MSE, SSIM performance of different models with cross validation method

	Data1	Data2	Data3	Data4	Data5	Data6	Data7	Data8	Data9	Data10	Avg
PSNR	35.23	35.41	36.35	36.22	35.31	36.57	35.16	36.72	35.96	35.05	35.798
MSE	7.26	7.39	7.14	6.96	7.28	6.94	7.36	7.08	7.43	7.32	7.216
SSIM	0.9536	0.9468	0.9540	0.9534	0.9461	0.9422	0.9432	0.9491	0.9444	0.9502	0.9483

表 2 各算法的 PSNR, MSE, SSIM 及 Time 值

Table 2 PSNR, MSE, SSIM and Time of different algorithms

	PSNR	MSE	SSIM	Time
NN	30.07	13.7	0.8563	0.008
bilinear	32.66	9.594	0.922	0.021
Bicubic	34.15	7.4	0.9356	0.022
FSRCNN	33.76	17.79	0.9296	0.052
SRCNN	33.78	18.06	0.9281	0.049
subPixel	33.99	18.28	0.9315	0.057
SRGAN	34.79	8.273	0.9376	0.299
Ours	35.798	7.216	0.9483	1.086

对比实验结果表明,基于深度学习的 SRCNN, FSRCNN, SubPixel CNN, SRGAN 的耗时均高于传统的 NN, bilinear 方法。本文方法对低分辨率图像重建之后,其在图像质量指标

PSNR, MSE 及 SSIM 上的分数最优。

4.3 主观评价

由图 6 可知,基于深度学习的 SubPixel CNN, SRGAN 算法处理的效果都明显优于传统的 Bilinear, NN 算法。主观来看, SubPixel CNN 算法、SRGAN 算法显示出了较好的超分辨率效果,获得了更逼真的细节纹理和图像锐度。

结束语 本文针对镜下白细胞图片细节模糊的问题,在 SRGAN 基础上对其进行结构上的改进,引入嵌套型残差密集块,用 Ragan 的思想对判别器的损失函数进行改进,并使用交叉验证对改进后的网络做出评估。然后将改进后的算法与几种基于插值及学习的超分辨率方法进行对比,结果表明,改进后的方法在 PSNR 及 SSIM 等客观指标和主观视觉效果上都优于对比方法,这充分说明了本文算法针对白细胞图片

进行超分辨率处理的适用性。下一步的研究工作将对重建的白细胞图像进行分类计数,以验证超分辨率工作的实用性。

参 考 文 献

- [1] WANG P, DALLA M M, CHANUSSOT J, et al. Soft-Then-Hard Super-Resolution Mapping Based on Pansharpening Technique for Remote Sensing Image[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 12(1):334-344.
- [2] WANG R, ZHANG Y, ZHANG J, et al. Face super-resolution reconstruction based on convolutional neural network[J]. Computer Engineering and Design, 2019, 40(9):2614-2619.
- [3] ISAAC J S, KULKARNI R. Super resolution techniques for medical image processing[C]//2015 International Conference on Technologies for Sustainable Development (ICTSD). IEEE, 2015:1-6.
- [4] SU H, ZHOU J, ZHANG Z H. Survey of super-resolution image reconstruction methods[J]. Acta Automatica Sinica, 2013, 39(8):1202-1213.
- [5] GAO Y, LIU Z, QIN P L, et al. Medical image super-resolution algorithm based on deep residual generative adversarial network[J]. Journal of Computer Applications, 2018, 38(9):2689-2695.
- [6] XIE T. Super-resolution image restoration via improved POCS algorithm[J]. Electronic Design Engineering, 2013, 21(18):142-144.
- [7] TAO Z Q, LI H L, ZHANG H B. Iterative Back Projection Super Resolution Reconstruction Algorithm Based on New Edge Directed Interpolation[J]. Computer Engineering, 2016, 42(6):255-260.
- [8] ZENG K, DING S F. Advances in image super-resolution reconstruction[J]. Computer Engineering and Applications, 2017, 53(16):29-35.
- [9] DONG C, LOY C C, HE K, et al. Learning a Deep Convolutional Network for Image Super-Resolution[C]//European Conference on Computer Vision. 2014:184-199.
- [10] DONG C, LOY C C, TANG X. Accelerating the Super-Resolution Convolutional Neural Network[C]//European Conference on Computer Vision. 2016:391-407.
- [11] KIM J, KWON L J, MU L K. Deeply-recursive convolutional network for image super resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:1637-1645.
- [12] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:4681-4690.
- [13] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Advances in Neural Information Processing Systems. 2014:2672-2680.
- [14] ZHANG H, XU T, LI H S. Stackgan: Text to photo-realistic image synthesis with stacked generative adversarial networks[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017:5907-5915.
- [15] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017:2223-2232.
- [16] MA L, JIA X, SUN Q, et al. Pose guided person image generation[C]//Advances in Neural Information Processing Systems. 2017:406-416.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:770-778.
- [18] WANG X, YU K, WU S, et al. Esrgan: Enhanced super-resolution generative adversarial networks[C]//Proceedings of the European Conference on Computer Vision(ECCV). 2018.
- [19] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:3883-3891.
- [20] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2014.
- [21] JOLICOEUR-MARTINEAU A. The relativistic discriminator: a key element missing from standard GAN[J]. arXiv:1807.00734, 2018.
- [22] SHI W, CABALLERO J, FERENC H, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:1874-1883.
- [23] TONG Y B, ZHANG Q S, QI Y P. Image quality assessing by combining PSNR with SSIM[J]. Journal of Image and Graphics, 2006, 12:1758-1763.



WANG Wei, born in 1977, associate professor. His main research interests include digital medical instruments and medical image processing.



LI Xin-wei, born in 1990, lecturer. Her main research interests include biomedical image processing and brain and cognitive science.