

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2021 年 2 月 11 日 (11.02.2021)



(10) 国际公布号
WO 2021/022752 A1

(51) 国际专利分类号:
G16H 30/20 (2018.01)

(21) 国际申请号: PCT/CN2019/125430

(22) 国际申请日: 2019 年 12 月 14 日 (14.12.2019)

(25) 申请语言: 中文

(26) 公布语言: 中文

(30) 优先权:
201910727072.9 2019 年 8 月 7 日 (07.08.2019) CN

(71) 申请人: 深圳先进技术研究院 (SHENZHEN INSTITUTE OF ADVANCED TECHNOLOGY) [CN/CN]; 中国广东省深圳市南山区西丽大学城学苑大道 1068 号, Guangdong 518055 (CN)。

(72) 发明人: 王书强 (WANG, Shuqiang); 中国广东省深圳市南山区西丽大学城学苑大道 1068 号, Guangdong 518055 (CN)。王鸿飞 (WANG, Hongfei); 中国广东省深圳市南山区西丽大学城学苑大道 1068 号, Guangdong 518055 (CN)。陈卓 (CHEN, Zhuo); 中国广东省深圳市南山区西丽大学城学苑大道 1068 号, Guangdong 518055 (CN)。

余雯 (YU, Wen); 中国广东省深圳市南山区西丽大学城学苑大道 1068 号, Guangdong 518055 (CN)。

(74) 代理人: 深圳市科进知识产权代理事务所 (普通合伙) (SHENZHEN KEJIN INTELLECTUAL PROPERTY OFFICE); 中国广东省深圳市南山区粤兴三道二号虚拟大学园产业化基地 A701 室, Guangdong 518055 (CN)。

(81) 指定国 (除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, ZA, ZM, ZW。

(84) 指定国 (除另有指明, 要求每一种可提供的地区保护): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM,

(54) Title: MULTIMODAL THREE-DIMENSIONAL MEDICAL IMAGE FUSION METHOD AND SYSTEM, AND ELECTRONIC DEVICE

(54) 发明名称: 一种多模态三维医学影像融合方法、系统及电子设备




图 5

(57) Abstract: Disclosed are a multimodal three-dimensional medical image fusion method and system, and an electronic device. The method comprises: constructing a multi-task generative adversarial network, wherein the multi-task generative adversarial network comprises a generator, a discriminator and a classifier; training the multi-task generative adversarial network according to an MRI image, a PET image and diagnosis label information of a subject; and inputting an MRI image of a person to be tested into the trained multi-task generative adversarial network, the generator synthesizing a corresponding PET image according to the MRI image and inputting the MRI image of said person and the synthesized PET image into the classifier, and outputting a disease classification prediction label of said person after the MRI image of said person and the synthesized PET image are fused. By means of the method, the problem in a traditional generative adversarial network of a conflict between loss function convergence points, which possibly occurs when the performance of a generator and the performance of a classifier are taken into consideration, is solved, such that the generator and the classifier can be optimal at the same time.

AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

本国际公布：

— 包括国际检索报告(条约第21条(3))。

(57) 摘要：一种多模态三维医学影像融合方法、系统及电子设备。包括：构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；根据受试者的MRI影像、PET影像和诊断标签信息对所述多任务生成对抗网络进行训练；将待检测者的MRI影像输入训练好的多任务生成对抗网络，生成器根据MRI影像合成对应的PET影像，并将待检测者的MRI影像与合成的PET影像输入分类器，所述将待检测者的MRI影像与合成的PET影像进入融合后输出待检测者的疾病分类预测标签。该方法解决了传统生成对抗网络在兼顾生成器和分类器性能时可能出现的损失函数收敛点的冲突问题，可以使生成器和分类器同时达到最优。

一种多模态三维医学影像融合方法、系统及电子设备

技术领域

本申请属于医学影像处理技术领域，特别涉及一种多模态三维医学影像融合方法、系统及电子设备。

背景技术

与MRI（Magnetic Resonance Imaging，磁共振成像）、CT（Computed Tomography，电子计算机断层扫描）等影像不同，PET（Positron Emission Computed Tomography，正电子发射型计算机断层显像）是一种对人体代谢过程进行体内观察的功能性成像技术，已逐渐广泛用于临床诊断和早期干预。具体而言，PET系统可以检测从放射性示踪剂间接发射的伽马射线，首先将示踪剂通过生物活性分子注入人体，然后利用计算机分析技术构建人体内示踪剂浓度的三维PET影像。PET的采集过程对人体健康造成不可避免的潜在威胁，调查显示，一次脑部PET扫描可以使患癌风险增加0.04%。虽然这个数字很小，但是在治疗过程中的反复扫描可以使患癌风险成倍增加。由于结构性影像MRI和功能性影像PET具有互补性，因此融合两种模态的影像数据可以获取更多用于分类诊断的关键特征，多模态融合的方法是当前提升辅助诊断模型性能的有效方法之一。但由于PET数据采集昂贵，样本量不够充足，很难获取足够的数据量训练模型。

生成式对抗网络最早由LanGoodfellow等人于2014年提出，继而引领了GAN改进和应用研究的热潮。2016年，Salimans等人对GAN训练和应用过程中出现的问题进行了理论分析和解释，并给出了经验性的解决方案（Improved-GAN）。Odena等人对GAN网络进行改进并应用于半监督学习中，利用无标签的数据和对抗训练策略提升分类器性能。当GAN用于图像生成时，

通常面临生成图像语义难以控制和无法保证图像多样性的问题。为此，Mehdi等人设计了基于条件控制的生成式对抗网络（conditional-GAN，cGAN），可以将数据标签或多模态属性作为条件变量，用于指导图像的生成。伯克利AI实验室学者Phillip等人在cGAN的基础上，将图像的不同风格作为约束条件，通过对抗训练策略优化生成器网络实现了由图像到图像的风格迁移。但是，基于cGAN的图像风格迁移网络受到任务要求的限制，输入图像和输出图像必须是成对的且内容一致。Zhu等人将两个cGAN组合设计了循环式生成对抗网络CycleGAN，并增加了损失函数的惩罚项，提升了图像风格迁移的效果且不再受内容一致性的限制。

Wang等人借鉴cGAN的基本框架并采用U-Net结构作为生成器网络，实现了由低剂量造影剂采集的PET生成高质量PET影像。并提出了一种递进式的生成网络架构，逐级提高合成影像的质量，这项研究对于降低PET成像成本和对人体的潜在辐射威胁具有重要意义。Nie等人融合cGAN网络和FCN实现了脑部MRI到CT影像的合成。针对腹腔部位医学影像空间复杂度高、合成误差大等问题，Hiasa等人设计了基于CycleGAN的跨模态影像合成方法，实现了由MRI到CT的迁移，降低了合成影像与真实影像之间的误差。最近，Pan等人设计了基于3D-CycleGAN的MRI-PET合成模型，实现了由MRI到PET的精准合成。并利用合成的PET和MRI进行特征融合用于AD（Alzheimer，阿尔兹海默症）和MCI(mild cognition impairment，轻度认知功能损害) 诊断。

然而，现有的生成对抗模型通常由分类网络和判别网络组成，在处理分类问题时判别网络同时兼顾样本真伪判别和模式分类的任务。这样会造成样本生成和模式分类收敛点的冲突问题，换言之，传统的生成模型无法用于处理多任务问题。同时，现有的基于条件生成对抗网络的跨模态影像合成方法是以给定

模态的影像作为条件约束信息，而没有考虑样本的标签信息。另外，现有的跨模态影像合成和分类诊断研究是对两个任务设计独立的模型并分别训练，没有考虑二者在优化过程中的关联性。

发明内容

本申请提供了一种多模态三维医学影像融合方法、系统及电子设备，旨在至少在一定程度上解决现有技术中的上述技术问题之一。

为了解决上述问题，本申请提供了如下技术方案：

一种多模态三维医学影像融合方法，包括以下步骤：

步骤 a：构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

步骤 b：根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练，使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征；

步骤 c：将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，所述生成器根据 MRI 影像合成对应的 PET 影像，并将待检测者的 MRI 影像与合成的 PET 影像输入分类器，所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

本申请实施例采取的技术方案还包括：在所述步骤 b 中，所述对多任务生成对抗网络进行训练具体包括：

步骤 b1：构建所述多任务生成对抗网络的对抗损失函数；训练过程的对抗损失用改进的极大极小代价函数进行表示：

$$\begin{aligned}
& \min_{C,G} \max_D U(C, G, D) \\
& = E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)] \\
& + \alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))] + (1 \\
& - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))]
\end{aligned}$$

上述公式中，(C,G,D)分别表示分类器、判别器和生成器，(x,y,z)分别表示MRI影像、PET影像和诊断标签信息； $\alpha \in (0,1)$ 是一个常量，用于控制分类器和生成器损失在训练过程中所占比重， $E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)]$ 表示判别器将来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))]$ 表示判别器识别出有分类器输出数据空间中的伪样本对； $(1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))]$ 表示判别器将自生成器的伪样本标签对识别出来，其中G(x,z)表示生成器产生的数据分布；

步骤 b2：对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x,y,z) \sim p(x,y,z)} [-\log p_c(x, y, z)]$ ，将分类器的样本分布 $p_c(x, y, z)$ 的收敛点限定在 $p(x, y)$ 附近，使模型的全局最优满足生成器G和分类器C产生的样本分布与真实数据分布相同；

步骤 b3：引入生成器监督损失，利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$\begin{aligned}
K_g &= NI(A, B) = G(A, B) \cdot I(A, B) \\
I(A, B) &= \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)} \\
G(A, B) &= \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|)
\end{aligned}$$

上述公式中，I(A,B)和G(A,B)分别表示生成图像与目标图像之间的梯度信息和梯度差值。

本申请实施例采取的技术方案还包括：在所述步骤b中，所述根据受试者的MRI影像、PET影像和诊断标签信息对所述多任务生成对抗网络进行训练还包括：所述生成器以MRI影像作为条件约束，将与目标图像同样维度的随机噪声输入映射为PET影像，所述判别器判定输入的样本分布 (x, y, z) 来自于真实数据分布还是伪数据分布，所述分类器以MRI影像和PET影像的联合分布作为输入，并预测其标签类型；在数据驱动模式下，随着生成器的逐渐优化，判别器更新网络参数以识别出生成器产生的伪数据分布；随着判别器的优化激励分类器优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器判定为伪数据，继而反向作用于生成器的训练；通过迭代对抗训练，使得所述生成器学习到MRI影像与PET影像之间的潜在关联特征，从而由输入的MRI影像合成得到相应的PET影像，并使得所述分类器从输入的MRI影像和PET影像提取关键特征信息并预测对应的疾病分类预测标签。

本申请实施例采取的技术方案还包括：所述生成器采用U-Net网络结构，其包括网络结构对称的编码器和解码器；在所述步骤c中，所述生成器根据MRI影像合成对应的PET影像具体包括：通过编码器多层卷积的特征提取运算，输出MRI影像的特征图；所述解码器对编码器输出的特征图进行多层反卷积运算，并将产生的特征图与编码器对应位置相同大小的特征图进行多次拼接操作，最终输出目标重构图像，即为合成的PET影像。

本申请实施例采取的技术方案还包括：在所述步骤c中，所述分类器将待检测者的MRI影像与合成的PET影像进入融合后输出待检测者的疾病分类预测标签具体包括：采用特征提取网络提取MRI影像的特征值，并对合成的PET影像进行卷积运算，提取PET影像的特征值；将所述MRI影像和PET影像的特征值进行拼接，组成拼接后的特征值，由全连接层对拼接后的特征值进行融合

和高维抽象；将融合后的特征信息经过Softmax函数运算得到对应的疾病分类预测标签。

本申请实施例采取的另一技术方案为：一种多模态三维医学影像融合系统，包括：

模型构建模块：用于构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

模型训练模块：用于根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练，使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征；

模型应用模块：用于将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，所述生成器根据 MRI 影像合成对应的 PET 影像，并将待检测者的 MRI 影像与合成的 PET 影像输入分类器，所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

本申请实施例采取的技术方案还包括：所述模型训练模块包括：

损失函数构建单元：用于构建所述多任务生成对抗网络的对抗损失函数；训练过程的对抗损失用改进的极大极小代价函数进行表示：

$$\begin{aligned} & \min_{C,G} \max_D U(C, G, D) \\ & = E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)] \\ & \quad + \alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))] + (1 \\ & \quad - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))] \end{aligned}$$

上述公式中，(C,G,D)分别表示分类器、判别器和生成器，(x,y,z)分别表示 MRI 影像、PET 影像和诊断标签信息； $\alpha \in (0,1)$ 是一个常量，用于控制分类器和生成器损失在训练过程中所占比重， $E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)]$ 表示判别器

将来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x,y,z))]$ 表示判别器识别出有分类器输出数据空间中的伪样本对； $(1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))]$ 表示判别器将自生成器的伪样本标签对识别出来，其中 x 表示受试样本的 MRI 模态影像， z 表示样本标签， $G(x, z)$ 表示条件生成网络合成的 PET 模态影像。

分类器优化单元：用于对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x,y,z) \sim p(x,y,z)} [-\log p_c(x,y,z)]$ ，将分类器的样本分布 $p_c(x,y,z)$ 的收敛点限定在 $p(x,y)$ 附近，使模型的全局最优满足生成器 G 和分类器 C 产生的样本分布与真实数据分布相同；

生成器优化单元：用于引入生成器监督损失，利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$K_g = NI(A, B) = G(A, B) \cdot I(A, B)$$

$$I(A, B) = \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)}$$

$$G(A, B) = \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|)$$

上述公式中， $I(A, B)$ 和 $G(A, B)$ 分别表示生成图像与目标图像之间的梯度信息和梯度差值。

本申请实施例采取的技术方案还包括：所述模型训练模块对多任务生成对抗网络进行训练具体为：所述生成器以 MRI 影像作为条件约束，将与目标图像同样维度的随机噪声输入映射为 PET 影像，所述判别器判定输入的样本分布 (x, y, z) 来自于真实数据分布还是伪数据分布，所述分类器以 MRI 影像和 PET 影像的联合分布作为输入，并预测其标签类型；在数据驱动模式下，随着生成器的逐渐优化，判别器更新网络参数以识别出生成器产生的伪数据分布；随着

判别器的优化激励分类器优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器判定为伪数据，继而反向作用于生成器的训练；通过迭代对抗训练，使得所述生成器学习到 MRI 影像与 PET 影像之间的潜在关联特征，从而由输入的 MRI 影像合成得到相应的 PET 影像，并使得所述分类器从输入的 MRI 影像和 PET 影像提取关键特征信息并预测对应的疾病分类预测标签。

本申请实施例采取的技术方案还包括：所述生成器采用U-Net网络结构，其包括网络结构对称的编码器和解码器；所述生成器根据MRI影像合成对应的PET影像具体包括：通过编码器多层卷积的特征提取运算，输出MRI影像的特征图；所述解码器对编码器输出的特征图进行多层反卷积运算，并将产生的特征图与编码器对应位置相同大小的特征图进行多次拼接操作，最终输出目标重构图像，即为合成的PET影像。

本申请实施例采取的技术方案还包括：所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签具体包括：采用特征提取网络提取 MRI 影像的特征值，并对合成的 PET 影像进行卷积运算，提取 PET 影像的特征值；将所述 MRI 影像和 PET 影像的特征值进行拼接，组成拼接后的特征值，由全连接层对拼接后的特征值进行融合和高维抽象；将融合后的特征信息经过 Softmax 函数运算得到对应的疾病分类预测标签。

本申请实施例采取的又一技术方案为：一种电子设备，包括：

至少一个处理器；以及

与所述至少一个处理器通信连接的存储器；其中，

所述存储器存储有可被所述一个处理器执行的指令，所述指令被所述至少一个处理器执行，以使所述至少一个处理器能够执行上述的多模态三维医学影像融合方法的以下操作：

步骤 a: 构建多任务生成对抗网络, 所述多任务生成对抗网络包括生成器、判别器和分类器;

步骤 b: 根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练, 使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征;

步骤 c: 将待检测者的 MRI 影像输入训练好的多任务生成对抗网络, 所述生成器根据 MRI 影像合成对应的 PET 影像, 并将待检测者的 MRI 影像与合成的 PET 影像输入分类器, 所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

相对于现有技术, 本申请实施例产生的有益效果在于: 本申请实施例的多模态三维医学影像融合方法、系统及电子设备提出了一种多任务生成对抗模型, 根据受试者病灶部位的 MRI 影像合成得到其在 PET 影像中的模式图像, 并融合真实的 MRI 影像与合成的 PET 影像后获取更多用于分类诊断的关键特征, 根据关键特征对疾病类型进行分类。相对于现有技术, 本申请至少具有以下有益效果:

1、通过设置单独的判别器, 其唯一作用是识别数据分布的真伪, 解决了传统生成对抗网络在兼顾生成器和分类器性能时可能出现的损失函数收敛点的冲突问题, 可以使生成器和分类器同时达到最优。

2、可实现跨模态影像合成模型和多模态融合分类模型的一步式协同训练, 可以实现更优的训练效果。训练好的生成模型学习到 MRI 与 PET 成像的关联特征, 可由待检测者的 MRI 合成其相应的 PET, 分类模型融合 MRI 与合成 PET 的特征信息进行疾病类型的分类诊断, 避免了 PET 采集高昂成本和辐射暴露风险的同时, 有效融合了功能性成像特征, 可以实现更高的分类精度。

3、本申请考虑了 MRI、PET 和诊断标签三种属性的联合分布，模型可以提取到多模态成像和分类诊断之间更丰富的关联特征信息，提升图像生成误差和分类诊断性能。通过大量病例的累积训练，逐步提高预测模型的准确率和鲁棒性。

4、本发明所提出的多任务生成对抗网络也可用于其他协同优化的应用场景。

附图说明

图 1 是本申请实施例的多模态三维医学影像融合方法的流程图；

图 2 是多任务生成对抗网络总体框架图；

图 3 是生成器的网络结构示意图；

图 4 是分类器的网络结构示意图；

图 5 是多任务生成对抗网络的应用流程图；

图 6 是本申请实施例的多模态三维医学影像融合系统的结构示意图；

图 7 是本申请实施例提供的多模态三维医学影像融合方法的硬件设备结构示意图。

具体实施方式

为了使本申请的目的、技术方案及优点更加清楚明白，以下结合附图及实施例，对本申请进行进一步详细说明。应当理解，此处所描述的具体实施例仅用以解释本申请，并不用于限定本申请。

针对多模态影像在临床诊断中的互补性和 PET 采集过程中的高成本及辐射暴露风险，本申请实施例的多模态三维医学影像融合方法提出了一种多任务生成对抗模型（Multi-Task GAN, MT-GAN），根据受试者病灶部位的 MRI 影

像预测出其在 PET 成像中的模式图像，在数据驱动模式下，实现跨模态影像合成网络和多模态融合分类网络的对抗协同训练，优化后的系统成功地学习到了 MRI 成像、PET 成像和疾病诊断之间的潜在关联特征，解决了传统生成对抗模型中生成网络和判别网络收敛点的冲突问题。本申请在无需待检测者进行 PET 采集的情况下融合了多源医学影像特征，可以更加精准地辅助医生进行临床诊断。为了清楚说明本申请的具体实施方案，以下实施例基于 MRI 和 PET 影像的阿尔茨海默症为例进行阐释，但本申请的应用范围并不仅限于病种阿尔茨海默症和 MRI-PET 影像，也可以广泛应用于其他疾病的 CT-PET、MRI-CT 等其他模态影像。

请参阅图 1，是本申请实施例的多模态三维医学影像融合方法的流程图。本申请实施例的多模态三维医学影像融合方法包括以下步骤：

步骤 100：采集受试者的 MRI 影像和 PET 影像，并对采集的 MRI 影像和 PET 影像进行预处理，得到用于训练模型的数据集；

步骤 100 中，采集 MRI 影像和 PET 影像具体为：分别选择阿尔茨海默症（AD）待检测者、轻度认知障碍（MCI）待检测者和正常老年人（Normal）各 300 位作为受试者，采集其脑部的 MRI 影像和 PET 影像作为原始数据集，并在每位受试者的临床观察和诊断中，由专业医师给出诊断信息，将诊断信息作为每位受试者的诊断标签信息。

原始数据集预处理具体为：采用 FSL、SPM 等技术对采集的脑部 MRI 和 PET 进行冗余组织剔除和图像校正处理，并利用 FSL 脑图像处理工具对 MRI 和 PET 影像进行线性配准操作，使 MRI 和 PET 影像在诊断意义上的解剖点达到空间位置的一致。

步骤200：构建多任务生成对抗网络；

步骤200中,多任务生成对抗网络框架如图2所示。多任务生成对抗网络需要考虑每个待检测者的MRI影像、PET影像和诊断标签信息三种属性,其包括分类器C、生成器G和判别器D,生成器G用于通过真实的MRI影像合成对应的PET影像;判别器D用于判定数据模式分布是来自于真实数据还是伪样本分布;分类器C用于将MRI影像和合成的PET影像进行融合后输出待检测者的疾病分类预测标签。将MRI影像、PET影像和诊断标签信息分别标记为 (x, y, z) ,则在多任务生成对抗网络中共包含真实数据分布 $p_{\text{true}}(x, y, z)$ 、生成器的样本分布 $p_G(x, y_g, z)$ 和分类器的样本分布 $p_c(x, y, z_l)$ 三种数据分布。生成器以MRI影像作为条件约束,将与目标图像同样维度的随机噪声输入映射为PET影像,实现 $p_G(x, y_g, z) = p_{\text{true}}(x, y, z)$ 的条件特征映射;分类器则以MRI影像和PET影像的联合分布作为输入,预测其标签类型,实现 $p_c(x, y, z_l) = p_{\text{true}}(x, y, z)$ 的条件特征映射;判别器则根据输入的样本分布 (x, y, z) 判定其是否来自于真实数据分布,实质是一个二分类问题。

本申请实施例中,生成器的网络结构如图3所示。生成器采用U-Net网络结构,U-Net模型基于跳跃式连接的全卷积网络而设计,其主要思路是设计网络结构对称的编码器和解码器,使其具有相同数量和大小的特征图,并通过跳跃式连接将编码器和解码器的对应特征图相结合,可以最大限度保留降采样过程中的特征信息,从而提高特征表达的效率。MRI影像和PET影像来自于同一样本,它们之间共享大量的初级特征信息,因此U-net模型很适合用于两种模态影像之间的复杂特征映射。

基于上述U-Net网络结构,生成器通过真实的MRI影像样本合成对应的PET影像的方式具体为:

(1) 通过编码器提取MRI影像的特征信息；以样本 $128 \times 128 \times 128$ 大小的MRI影像作为输入，经过64个 $2 \times 2 \times 2$ 大小卷积核的特征提取运算，在三个维度上滑动步长为2，输出64个大小为 $64 \times 64 \times 64$ 的特征图。然后利用128个 $2 \times 2 \times 2$ 大小的卷积核对其进行卷积运算，产生128个 $32 \times 32 \times 32$ 大小的特征图。以此类推，依次经过编码器6层卷积的特征提取运算，输出1024个特征图。

(2) 解码器对编码器输出的特征图进行重构；首先，对编码器输出的1024个特征图进行反卷积运算，产生512个 $2 \times 2 \times 2$ 的特征图，并与编码器对应位置相同大小的特征图进行拼接。依次经过6层反卷积运算和拼接操作，最终输出 $128 \times 128 \times 128$ 大小的目标重构图像，即为合成的PET影像。

为了降低模型的运算复杂度、提高网络的协同训练效率，本申请实施例中的分类器选择了一种相对简单的多模态融合分类网络，其结构如图4所示。分类器对多模态影像数据的处理流程为：

(1) 采用特征提取网络提取MRI影像的特征信息；首先利用 $2 \times 2 \times 2$ 大小卷积核的两个卷积层提取影像的初级特征产生32个特征图，再利用一层窗口大小为 $2 \times 2 \times 2$ 的池化层对特征图进行降维。随后采用 $3 \times 3 \times 3$ 大小的卷积核提取高级特征，第三和第四个卷积层分别采用64个卷积核，提取到的特征池化降维，之后采用128个卷积核进行更高维特征提取。

(2) 采用同样结构的特征提取网络对PET影像进行卷积运算，产生128个特征值。

(3) 将从MRI影像和PET影像提取到的特征值进行拼接，组成256个特征值，由包含54个节点的全连接层对两种模态的特征信息进行融合和高维抽象。

(4) 将整合后的融合特征信息经过Softmax函数运算得到对应的标签预测类型（即预测影像数据对应疾病等级的概率）。

步骤300：根据受试者的MRI影像、PET影像和诊断标签信息对多任务生成对抗网络进行训练；

步骤300中，多任务生成对抗网络的训练过程包括以下步骤：

步骤301：构建模型的对抗损失函数；

在模型的实际应用过程中，需对每个待检测者的MRI数据进行采集，因此生成器和分类器的预测过程分别为如下条件分布：

$$p_g(x, y_g) = p(y|x)p(x) \quad (1)$$

$$p_c(x, y, z) = p[z|(x, y)]p(x, y) \quad (2)$$

训练过程的对抗损失可以用改进的极大极小代价函数进行表示：

$$\min_{C, G} \max_D U(C, G, D) = E_{(x, y, z) \sim p(x, y, z)} [\log D(x, y, z)] + \alpha E_{(x, y, z) \sim p_c(x, y, z)} [\log(1 - D(x, y, z))] + (1 - \alpha) E_{(x, y, z) \sim p_g(x, y, z)} [\log(1 - D(x, G(x, z), z))] \quad (3)$$

公式（3）中， $\alpha \in (0, 1)$ 是一个常量，用于控制分类器和生成器损失在训练过程中所占比重，即在对抗训练任务中的相对重要性。 $E_{(x, y, z) \sim p(x, y, z)} [\log D(x, y, z)]$ 表示判别器将来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x, y, z) \sim p_c(x, y, z)} [\log(1 - D(x, y, z))]$ 表示判别器识别出有分类器输出数据空间中的伪样本对； $(1 - \alpha) E_{(x, y, z) \sim p_g(x, y, z)} [\log(1 - D(x, G(x, z), z))]$ 表示判别器将自生成器的伪样本标签对识别出来，其中 x 表示受试样本的 MRI 模态影像， z 表示样本标签， $G(x, z)$ 表示条件生成网络合成的 PET 模态影像。由此构建了多任务生成对抗网络的对抗损失函数。

步骤 302：引入分类器监督损失；由一般对抗生成网络的优化原理可知，

模型当且仅当 $p(x, y, z) = (1 - \alpha)p_g(x, y_g, z) + \alpha p_c(x, y, z)$ 时达到纳什均衡。对抗博弈的均衡表明，当生成器 G 和分类器 C 中的其中一个达到最优时，另一个也趋近于最优。但事实上，模型的全局最优应当满足生成器 G 和分类器 C 产生的样本分布与真实数据分布相同，即 $p(x, y, z) = p_g(x, y, z) = p_c(x, y, z)$ 。但上述损失函数的解是 $p(x, y, z) = (1 - \alpha)p_g(x, y, z) + \alpha p_c(x, y, z)$ 的子集，无法保证 $p(x, y, z) = p_g(x, y, z) = p_c(x, y, z)$ 。因此，本申请通过在训练中对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x, y, z) \sim p(x, y, z)}[-\log p_c(x, y, z)]$ ，从而将 $p_c(x, y, z)$ 的收敛点限定在 $p(x, y)$ 附近，继而保证损失函数的解是全局最优解。

步骤 303：引入生成器监督损失；

在生成器训练中，从损失函数设计上除了需要生成样本让判别器难以识别，还要保证生成样本与目标图像尽可能相似。本申请利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$K_g = NI(A, B) = G(A, B) \cdot I(A, B) \quad (4)$$

$$I(A, B) = \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)} \quad (5)$$

$$G(A, B) = \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|) \quad (6)$$

上述公式中， $I(A, B)$ 和 $G(A, B)$ 分别表示生成图像与目标图像之间的梯度信息和梯度差值。

综上所述，本申请所提出的多任务生成对抗网络的目标函数为：

$$\begin{aligned} \min_{C, G} \max_D U(C, G, D) = \\ E_{(x, y, z) \sim p(x, y, z)} [\log D(x, y, z)] + \alpha E_{(x, y, z) \sim p_c(x, y, z)} [\log(1 - D(x, y, z))] + (1 - \\ \alpha) E_{(x, y, z) \sim p_g(x, y, z)} [\log(1 - D(x, G(y, z), z))] + K_c + K_g \quad (7) \end{aligned}$$

步骤 304：将 900 个受试者的数据集划分训练集和测试集，通过训练集对多任务生成对抗网络进行训练，并通过测试集对多任务生成对抗网络的性能进

行测试；

步骤 304 中，训练集中的样本数据为 700 个，测试集中样本数据为 200 个。模型的训练过程具体为：在数据驱动模式下，随着生成器 G 的逐渐优化，判别器 D 需更新网络参数以识别出生成器 G 产生的伪数据分布；随着判别器 D 的优化激励分类器 C 优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器 D 判定为伪数据，继而反向作用于生成器 G 的训练。通过如此对多任务生成对抗网络进行迭代训练，使得生成器 G 和分类器 C 在对抗训练中达到最优，且在三者的对抗博弈过程中，使得分类器和生成器取得比单独训练更好的性能。

步骤 400：将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，多任务生成对抗网络输出待检测者的疾病分类预测标签；

步骤 400 中，通过对抗训练后，生成器 G 学习到了 MRI 影像与 PET 影像之间的潜在关联特征，可以更加准确地由输入的 MRI 影像合成得到相应的 PET 影像。分类器的参数也实现最优化，可以从输入的 MRI 影像和 PET 影像提取关键特征信息并基于该特征预测对应的疾病分类预测标签。

具体请一并参阅图 5，多任务生成对抗网络的应用流程具体包括以下步骤：

步骤 401：采集待检测者的 MRI 影像；

步骤 402：将 MRI 影像输入训练好的生成器中进行合成，生成器根据 MRI 影像合成对应的 PET 影像；

步骤 403：将 MRI 影像与合成的 PET 影像输入到训练好的分类器中，分类器输出待检测者的疾病分类预测标签。

请参阅图 6，是本申请实施例的多模态三维医学影像融合系统的结构示意图。本申请实施例的多模态三维医学影像融合系统包括数据采集模块、模型构

建模块、模型训练模块和模型应用模块。

数据采集模块：用于采集受试者的 MRI 影像和 PET 影像，并对采集的 MRI 影像和 PET 影像进行预处理，得到用于训练模型的数据集；其中，采集 MRI 影像和 PET 影像具体为：分别选择阿尔茨海默症（AD）待检测者、轻度认知障碍（MCI）待检测者和正常老年人（Normal）各 300 位作为受试者，采集其脑部的 MRI 影像和 PET 影像作为原始数据集，并在每位受试者的临床观察和诊断中，由专业医师给出诊断信息，将诊断信息作为每位受试者的诊断标签信息。

MRI 影像和 PET 影像预处理具体为：采用 FSL、SPM 等技术对采集的脑部 MRI 和 PET 进行冗余组织剔除和图像校正处理，并利用 FSL 脑图像处理工具对 MRI 和 PET 影像进行线性配准操作，使 MRI 和 PET 影像在诊断意义上的解剖点达到空间位置的一致。

模型构建模块：用于构建多任务生成对抗网络；其中，多任务生成对抗网络包括分类器C、生成器G和判别器D，生成器G用于通过真实的MRI影像合成对应的PET影像；判别器D用于判定数据模式分布是来自于真实数据还是伪样本分布；分类器C用于将MRI影像和合成的PET影像进行融合后输出待检测者的疾病分类预测标签。将MRI影像、PET影像和诊断标签信息分别标记为 (x, y, z) ，则在多任务生成对抗网络中共包含真实数据分布 $p_{\text{true}}(x, y, z)$ 、生成器的样本分布 $p_G(x, y_g, z)$ 和分类器的样本分布 $p_c(x, y, z_l)$ 三种数据分布。生成器以MRI影像作为条件约束，将与目标图像同样维度的随机噪声输入映射为PET影像，实现 $p_G(x, y_g, z) = p_{\text{true}}(x, y, z)$ 的条件特征映射；分类器则以MRI影像和PET影像的联合分布作为输入，预测其标签类型，实现 $p_c(x, y, z_l) = p_{\text{true}}(x, y, z)$

的条件特征映射；判别器则根据输入的样本分布 (x, y, z) 判定其是否来自于真实数据分布，实质是一个二分类问题。

本申请实施例中，生成器采用U-Net网络结构，U-Net模型基于跳跃式连接的全卷积网络而设计，其主要思路是设计网络结构对称的编码器和解码器，使其具有相同数量和大小特征图，并通过跳跃式连接将编码器和解码器的对应特征图相结合，可以最大限度保留降采样过程中的特征信息，从而提高特征表达的效率。MRI影像和PET影像来自于同一样本，它们之间共享大量的初级特征信息，因此U-net模型很适合用于两种模态影像之间的复杂特征映射。

基于上述U-Net网络结构，生成器通过真实的MRI影像样本合成对应的PET影像的方式具体为：

(1) 通过编码器提取MRI影像的特征信息；以样本 $128 \times 128 \times 128$ 大小的MRI影像作为输入，经过64个 $2 \times 2 \times 2$ 大小卷积核的特征提取运算，在三个维度上滑动步长为2，输出64个大小为 $64 \times 64 \times 64$ 的特征图。然后利用128个 $2 \times 2 \times 2$ 大小的卷积核对其进行卷积运算，产生128个 $32 \times 32 \times 32$ 大小的特征图。以此类推，依次经过编码器6层卷积的特征提取运算，输出1024个特征图。

(2) 解码器对编码器输出的特征图进行重构；首先，对编码器输出的1024个特征图进行反卷积运算，产生512个 $2 \times 2 \times 2$ 的特征图，并与编码器对应位置相同大小的特征图进行拼接。依次经过6层反卷积运算和拼接操作，最终输出 $128 \times 128 \times 128$ 大小的目标重构图像，即为合成的PET影像。

为了降低模型的运算复杂度、提高网络的协同训练效率，本申请实施例中的分类器选择了一种相对简单的多模态融合分类网络，分类器对多模态影像数据的处理流程为：

(1) 提取MRI影像的特征信息；首先利用 $2 \times 2 \times 2$ 大小卷积核的两个卷积层提取影像的初级特征产生32个特征图，再利用一层窗口大小为 $2 \times 2 \times 2$ 的池化层对特征图进行降维。随后采用 $3 \times 3 \times 3$ 大小的卷积核提取高级特征，第三和第四个卷积层分别采用64个卷积核，提取到的特征池化降维，之后采用128个卷积核进行更高维特征提取。

(2) 采用同样结构的特征提取网络对PET影像进行卷积运算，产生128个特征值。

(3) 将从MRI影像和PET影像提取到的特征值进行拼接，组成256个特征值，由包含54个节点的全连接层对两种模态的特征信息进行融合和高维抽象。

(4) 将整合后的融合特征信息经过Softmax函数运算得到对应的标签预测类型（即预测影像数据对应疾病等级的概率）。

模型训练模块：用于根据受试者的MRI影像、PET影像和诊断标签信息对多任务生成对抗网络进行训练；模型训练模块包括：

损失函数构建单元：用于构建模型的对抗损失函数；在模型的实际应用过程中，需对每个待检测者的MRI数据进行采集，因此生成器和分类器的预测过程分别为如下条件分布：

$$p_g(x, y_g) = p(y|x)p(x) \quad (1)$$

$$p_c(x, y, z) = p[z|(x, y)]p(x, y) \quad (2)$$

训练过程的对抗损失可以用改进的极大极小代价函数进行表示：

$$\min_{C, G} \max_D U(C, G, D) = E_{(x, y, z) \sim p(x, y, z)} [\log D(x, y, z)] + \alpha E_{(x, y, z) \sim p_c(x, y, z)} [\log(1 - D(x, y, z))] + (1 - \alpha) E_{(x, y, z) \sim p_g(x, y, z)} [\log(1 - D(x, G(x, z), z))] \quad (3)$$

公式（3）中， $\alpha \in (0, 1)$ 是一个常量，用于控制分类器和生成器损失在训

练过程中所占比重，即在对抗训练任务中的相对重要性。

$E_{(x,y,z) \sim p(x,y,z)}[\log D(x,y,z)]$ 表示判别器将来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x,y,z) \sim p_c(x,y,z)}[\log(1 - D(x,y,z))]$ 表示判别器识别出有分类器输出数据空间中的伪样本对； $(1 - \alpha)E_{(x,y,z) \sim p_g(x,y,z)}[\log(1 - D(x, G(x,z), z))]$ 。由此构建了多任务生成对抗网络的对抗损失函数。

分类器优化单元：用于引入分类器监督损失；由一般对抗生成网络的优化原理可知，模型当且仅当 $p(x,y,z) = (1 - \alpha)p_g(x,y_g,z) + \alpha p_c(x,y,z)$ 时达到纳什均衡。对抗博弈的均衡表明，当生成器 G 和分类器 C 中的其中一个达到最优时，另一个也趋近于最优。但事实上，模型的全局最优应当满足生成器 G 和分类器 C 产生的样本分布与真实数据分布相同，即 $p(x,y,z) = p_g(x,y,z) = p_c(x,y,z)$ 。但上述损失函数的解是 $p(x,y,z) = (1 - \alpha)p_g(x,y,z) + \alpha p_c(x,y,z)$ 的子集，无法保证 $p(x,y,z) = p_g(x,y,z) = p_c(x,y,z)$ 。因此，本申请通过在训练中对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x,y,z) \sim p(x,y,z)}[-\log p_c(x,y,z)]$ ，从而将 $p_c(x,y,z)$ 的收敛点限定在 $p(x,y)$ 附近，继而保证损失函数的解是全局最优解。

生成器优化单元：用于引入生成器监督损失；在生成器训练中，从损失函数设计上除了需要生成样本让判别器难以识别，还要保证生成样本与目标图像尽可能相似。本申请利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$K_g = NI(A, B) = G(A, B) \cdot I(A, B) \quad (4)$$

$$I(A, B) = \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)} \quad (5)$$

$$G(A, B) = \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|) \quad (6)$$

上述公式中， $I(A, B)$ 和 $G(A, B)$ 分别表示生成图像与目标图像之间的梯度信

息和梯度差值。

综上所述，本申请所提出的多任务生成对抗网络的目标函数为：

$$\min_{C,G} \max_D U(C, G, D) = E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)] + \alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))] + (1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(y, z), z))] + K_C + K_g \quad (7)$$

模型训练单元：用于将 900 个受试者的数据集划分训练集和测试集，通过训练集对多任务生成对抗网络进行训练，并通过测试集对多任务生成对抗网络的性能进行测试；其中，训练集中的样本数据为 700 个，测试集中样本数据为 200 个。模型的训练过程具体为：在数据驱动模式下，随着生成器 G 的逐渐优化，判别器 D 需更新网络参数以识别出生成器 G 产生的伪数据分布；随着判别器 D 的优化激励分类器 C 优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器 D 判定为伪数据，继而反向作用于生成器 G 的训练。通过如此对多任务生成对抗网络进行迭代训练，使得生成器 G 和分类器 C 在对抗训练中达到最优，且在三者的对抗博弈过程中，使得分类器和生成器取得比单独训练更好的性能。

模型应用模块：用于将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，多任务生成对抗网络输出待检测者的疾病分类预测标签；通过对抗训练后，生成器 G 学习到了 MRI 影像与 PET 影像之间的潜在关联特征，可以更加准确地由输入的 MRI 影像合成得到相应的 PET 影像。分类器的参数也实现最优化，可以从输入的 MRI 影像和 PET 影像提取关键特征信息并基于该特征预测对应的疾病分类预测标签。

具体的，多任务生成对抗网络的应用过程具体为：采集待检测者的 MRI 影像，将 MRI 影像输入训练好的生成器中进行合成，生成器根据 MRI 影像合

成对应的 PET 影像；将 MRI 影像与合成的 PET 影像输入到训练好的分类器中，分类器输出待检测者的疾病分类预测标签。

图 7 是本申请实施例提供的多模态三维医学影像融合方法的硬件设备结构示意图。如图 7 所示，该设备包括一个或多个处理器以及存储器。以一个处理器为例，该设备还可以包括：输入系统和输出系统。

处理器、存储器、输入系统和输出系统可以通过总线或者其他方式连接，图 7 中以通过总线连接为例。

存储器作为一种非暂态计算机可读存储介质，可用于存储非暂态软件程序、非暂态计算机可执行程序以及模块。处理器通过运行存储在存储器中的非暂态软件程序、指令以及模块，从而执行电子设备的各种功能应用以及数据处理，即实现上述方法实施例的处理方法。

存储器可以包括存储程序区和存储数据区，其中，存储程序区可存储操作系统、至少一个功能所需要的应用程序；存储数据区可存储数据等。此外，存储器可以包括高速随机存取存储器，还可以包括非暂态存储器，例如至少一个磁盘存储器件、闪存器件、或其他非暂态固态存储器件。在一些实施例中，存储器可选包括相对于处理器远程设置的存储器，这些远程存储器可以通过网络连接至处理系统。上述网络的实例包括但不限于互联网、企业内部网、局域网、移动通信网及其组合。

输入系统可接收输入的数字或字符信息，以及产生信号输入。输出系统可包括显示屏等显示设备。

所述一个或者多个模块存储在所述存储器中，当被所述一个或者多个处理器执行时，执行上述任一方法实施例的以下操作：

步骤 a: 构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

步骤 b: 根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务

生成对抗网络进行训练,使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征;

步骤 c: 将待检测者的 MRI 影像输入训练好的多任务生成对抗网络,所述生成器根据 MRI 影像合成对应的 PET 影像,并将待检测者的 MRI 影像与合成的 PET 影像输入分类器,所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

上述产品可执行本申请实施例所提供的方法,具备执行方法相应的功能模块和有益效果。未在本实施例中详尽描述的技术细节,可参见本申请实施例提供的方法。

本申请实施例提供了一种非暂态(非易失性)计算机存储介质,所述计算机存储介质存储有计算机可执行指令,该计算机可执行指令可执行以下操作:

步骤 a: 构建多任务生成对抗网络,所述多任务生成对抗网络包括生成器、判别器和分类器;

步骤 b: 根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练,使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征;

步骤 c: 将待检测者的 MRI 影像输入训练好的多任务生成对抗网络,所述生成器根据 MRI 影像合成对应的 PET 影像,并将待检测者的 MRI 影像与合成的 PET 影像输入分类器,所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

本申请实施例提供了一种计算机程序产品,所述计算机程序产品包括存储的非暂态计算机可读存储介质上的计算机程序,所述计算机程序包括程序指令,当所述程序指令被计算机执行时,使所述计算机执行以下操作:

步骤 a: 构建多任务生成对抗网络, 所述多任务生成对抗网络包括生成器、判别器和分类器;

步骤 b: 根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练, 使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征;

步骤 c: 将待检测者的 MRI 影像输入训练好的多任务生成对抗网络, 所述生成器根据 MRI 影像合成对应的 PET 影像, 并将待检测者的 MRI 影像与合成的 PET 影像输入分类器, 所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

本申请实施例的多模态三维医学影像融合方法、系统及电子设备提出了一种多任务生成对抗模型, 根据受试者病灶部位的 MRI 影像合成得到其在 PET 影像中的模式图像, 并融合真实的 MRI 影像与合成的 PET 影像后获取更多用于分类诊断的关键特征, 根据关键特征对疾病类型进行分类。相对于现有技术, 本申请至少具有以下有益效果:

1、通过设置单独的判别器, 其唯一作用是识别数据分布的真伪, 解决了传统生成对抗网络在兼顾生成器和分类器性能时可能出现的损失函数收敛点的冲突问题, 可以使生成器和分类器同时达到最优。

2、可实现跨模态影像合成模型和多模态融合分类模型的一步式协同训练, 可以实现更优的训练效果。训练好的生成模型学习到 MRI 与 PET 成像的关联特征, 可由待检测者的 MRI 合成其相应的 PET, 分类模型融合 MRI 与合成 PET 的特征信息进行疾病类型的分类诊断, 避免了 PET 采集高昂成本和辐射暴露风险的同时, 有效融合了功能性成像特征, 可以实现更高的分类精度。

3、本申请考虑了 MRI、PET 和诊断标签三种属性的联合分布, 模型可以

提取到多模态成像和分类诊断之间更丰富的关联特征信息，提升图像生成误差和分类诊断性能。通过大量病例的累积训练，逐步提高预测模型的准确率和鲁棒性。

4、本发明所提出的多任务生成对抗网络也可用于其他协同优化的应用场景。

以上所述仅是本发明的优选实施方式，应当指出，对于本技术领域的普通技术人员来说，在不脱离本发明原理的前提下，还可以做出若干改进和润饰，这些改进和润饰也应视为本发明的保护范围。

权 利 要 求

1、一种多模态三维医学影像融合方法，其特征在于，包括以下步骤：

步骤 a：构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

步骤 b：根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练，使所述多任务生成对抗网络自动学习 MRI 影像和 PET 影像之间的关联特征；

步骤 c：将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，所述生成器根据 MRI 影像合成对应的 PET 影像，并将待检测者的 MRI 影像与合成的 PET 影像输入分类器，所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

2、根据权利要求 1 所述的多模态三维医学影像融合方法，其特征在于，在所述步骤 b 中，所述对多任务生成对抗网络进行训练具体包括：

步骤 b1：构建所述多任务生成对抗网络的对抗损失函数；训练过程的对抗损失用改进的极大极小代价函数进行表示：

$$\begin{aligned} \min_{C,G} \max_D U(C, G, D) \\ = E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)] + \alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))] \\ + (1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))] \end{aligned}$$

上述公式中，(C,G,D)分别表示分类器、判别器和生成器，(x,y,z)分别表示 MRI 影像、PET 影像和诊断标签信息； $\alpha \in (0,1)$ 是一个常量，用于控制分类器和生成器损失在训练过程中所占比重， $E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)]$ 表示判别器来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))]$

表示判别器识别出有分类器输出数据空间中的伪样本对；
 $(1 - \alpha)E_{(x,y,z) \sim p_g(x,y,z)}[\log(1 - D(x, G(x, z), z))]$ 表示判别器将自生成器的伪样本标签对识别出来，其中 x 表示受试样本的 MRI 模态影像， z 表示样本标签， $G(x, z)$ 表示条件生成网络合成的 PET 模态影像；

步骤 b2：对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x,y,z) \sim p(x,y,z)}[-\log p_c(x, y, z)]$ ，将分类器的样本分布 $p_c(x, y, z)$ 的收敛点限定在 $p(x, y)$ 附近，使模型的全局最优满足生成器 G 和分类器 C 产生的样本分布与真实数据分布相同；

步骤 b3：引入生成器监督损失，利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$K_g = NI(A, B) = G(A, B) \cdot I(A, B)$$

$$I(A, B) = \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)}$$

$$G(A, B) = \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|)$$

上述公式中， $I(A, B)$ 和 $G(A, B)$ 分别表示生成图像与目标图像之间的梯度信息和梯度差值。

3、根据权利要求 2 所述的多模态三维医学影像融合方法，其特征在于，在所述步骤 b 中，所述根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练还包括：所述生成器以 MRI 影像作为条件约束，将与目标图像同样维度的随机噪声输入映射为 PET 影像，所述判别器判定输入的样本分布 (x, y, z) 来自于真实数据分布还是伪数据分布，所述分类器以 MRI 影像和 PET 影像的联合分布作为输入，并预测其标签类型；在数据驱动模式下，随着生成器的逐渐优化，判别器更新网络参数以识别出生成器产生的伪数据分布；

随着判别器的优化激励分类器优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器判定为伪数据，继而反向作用于生成器的训练；通过迭代对抗训练，使得所述生成器学习到 MRI 影像与 PET 影像之间的潜在关联特征，从而由输入的 MRI 影像合成得到相应的 PET 影像，并使得所述分类器从输入的 MRI 影像和 PET 影像提取关键特征信息并预测对应的疾病分类预测标签。

4、根据权利要求1至3任一项所述的多模态三维医学影像融合方法，其特征在于，所述生成器采用U-Net网络结构，其包括网络结构对称的编码器和解码器；在所述步骤c中，所述生成器根据MRI影像合成对应的PET影像具体包括：通过编码器多层卷积的特征提取运算，输出MRI影像的特征图；所述解码器对编码器输出的特征图进行多层反卷积运算，并将产生的特征图与编码器对应位置相同大小的特征图进行多次拼接操作，最终输出目标重构图像，即为合成的PET影像。

5、根据权利要求4所述的多模态三维医学影像融合方法，其特征在于，在所述步骤c中，所述分类器将待检测者的MRI影像与合成的PET影像进入融合后输出待检测者的疾病分类预测标签具体包括：采用特征提取网络提取MRI影像的特征值，并对合成的PET影像进行卷积运算，提取PET影像的特征值；将所述MRI影像和PET影像的特征值进行拼接，组成拼接后的特征值，由全连接层对拼接后的特征值进行融合和高维抽象；将融合后的特征信息经过Softmax函数运算得到对应的疾病分类预测标签。

6、一种多模态三维医学影像融合系统，其特征在于，包括：

模型构建模块：用于构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

模型训练模块：用于根据受试者的 MRI 影像、PET 影像和诊断标签信息对所述多任务生成对抗网络进行训练，使所述多任务生成对抗网络自动学习 MRI

影像和 PET 影像之间的关联特征；

模型应用模块：用于将待检测者的 MRI 影像输入训练好的多任务生成对抗网络，所述生成器根据 MRI 影像合成对应的 PET 影像，并将待检测者的 MRI 影像与合成的 PET 影像输入分类器，所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。

7、根据权利要求 6 所述的多模态三维医学影像融合系统，其特征在于，所述模型训练模块包括：

损失函数构建单元：用于构建所述多任务生成对抗网络的对抗损失函数；训练过程的对抗损失用改进的极大极小代价函数进行表示：

$$\begin{aligned} \min_{C,G} \max_D U(C, G, D) \\ = E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)] + \alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))] \\ + (1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))] \end{aligned}$$

上述公式中，(C,G,D)分别表示分类器、判别器和生成器，(x,y,z)分别表示 MRI 影像、PET 影像和诊断标签信息； $\alpha \in (0,1)$ 是一个常量，用于控制分类器和生成器损失在训练过程中所占比重， $E_{(x,y,z) \sim p(x,y,z)} [\log D(x, y, z)]$ 表示判别器将来自于真实数据分布中的样本判定为真实样本； $\alpha E_{(x,y,z) \sim p_c(x,y,z)} [\log(1 - D(x, y, z))]$ 表示判别器识别出有分类器输出数据空间中的伪样本对； $(1 - \alpha) E_{(x,y,z) \sim p_g(x,y,z)} [\log(1 - D(x, G(x, z), z))]$ 表示判别器将自生成器的伪样本标签对识别出来，其中 x 表示受试样本的 MRI 模态影像，z 表示样本标签，G(x, z) 表示条件生成网络合成的 PET 模态影像；

分类器优化单元：用于对分类器引入监督学习下的交叉熵损失 $K_c = E_{(x,y,z) \sim p(x,y,z)} [-\log p_c(x, y, z)]$ ，将分类器的样本分布 $p_c(x, y, z)$ 的收敛点限定在 $p(x, y)$ 附近，使模型的全局最优满足生成器 G 和分类器 C 产生的样本分布与真

实数据分布相同；

生成器优化单元：用于引入生成器监督损失，利用目标图像与生成图像之间的梯度互信息作为相似性度量：

$$K_g = NI(A, B) = G(A, B) \cdot I(A, B)$$

$$I(A, B) = \sum_{a \in A, b \in B} p_{AB}(a, b) \cdot \log \frac{p_{AB}(a, b)}{p_A(a) \cdot p_B(b)}$$

$$G(A, B) = \sum_{(x, x') \in (A \cap B)} \omega(\alpha_{x, x'}(\sigma)) \min(|\nabla x(\sigma)|, |\nabla x'(\sigma)|)$$

上述公式中， $I(A, B)$ 和 $G(A, B)$ 分别表示生成图像与目标图像之间的梯度信息和梯度差值。

8、根据权利要求 7 所述的多模态三维医学影像融合系统，其特征在于，所述模型训练模块对多任务生成对抗网络进行训练具体为：所述生成器以 MRI 影像作为条件约束，将与目标图像同样维度的随机噪声输入映射为 PET 影像，所述判别器判定输入的样本分布 (x, y, z) 来自于真实数据分布还是伪数据分布，所述分类器以 MRI 影像和 PET 影像的联合分布作为输入，并预测其标签类型；在数据驱动模式下，随着生成器的逐渐优化，判别器更新网络参数以识别出生成器产生的伪数据分布；随着判别器的优化激励分类器优化使其预测的疾病分类预测标签趋向于真实数据而不会被判别器判定为伪数据，继而反向作用于生成器的训练；通过迭代对抗训练，使得所述生成器学习到 MRI 影像与 PET 影像之间的潜在关联特征，从而由输入的 MRI 影像合成得到相应的 PET 影像，并使得所述分类器从输入的 MRI 影像和 PET 影像提取关键特征信息并预测对应的疾病分类预测标签。

9、根据权利要求6至8任一项所述的多模态三维医学影像融合系统，其特征在于，所述生成器采用U-Net网络结构，其包括网络结构对称的编码器和解码器；

所述生成器根据MRI影像合成对应的PET影像具体包括：通过编码器多层卷积的特征提取运算，输出MRI影像的特征图；所述解码器对编码器输出的特征图进行多层反卷积运算，并将产生的特征图与编码器对应位置相同大小的特征图进行多次拼接操作，最终输出目标重构图像，即为合成的PET影像。

10、根据权利要求9所述的多模态三维医学影像融合系统，其特征在于，所述分类器将待检测者的MRI影像与合成的PET影像进入融合后输出待检测者的疾病分类预测标签具体包括：采用特征提取网络提取MRI影像的特征值，并对合成的PET影像进行卷积运算，提取PET影像的特征值；将所述MRI影像和PET影像的特征值进行拼接，组成拼接后的特征值，由全连接层对拼接后的特征值进行融合和高维抽象；将融合后的特征信息经过Softmax函数运算得到对应的疾病分类预测标签。

11、一种电子设备，包括：

至少一个处理器；以及

与所述至少一个处理器通信连接的存储器；其中，

所述存储器存储有可被所述一个处理器执行的指令，所述指令被所述至少一个处理器执行，以使所述至少一个处理器能够执行上述1至5任一项所述的多模态三维医学影像融合方法的以下操作：

步骤a：构建多任务生成对抗网络，所述多任务生成对抗网络包括生成器、判别器和分类器；

步骤b：根据受试者的MRI影像、PET影像和诊断标签信息对所述多任务生成对抗网络进行训练，使所述多任务生成对抗网络自动学习MRI影像和PET影像之间的关联特征；

步骤c：将待检测者的MRI影像输入训练好的多任务生成对抗网络，所述

生成器根据 MRI 影像合成对应的 PET 影像,并将待检测者的 MRI 影像与合成的 PET 影像输入分类器,所述分类器将待检测者的 MRI 影像与合成的 PET 影像进入融合后输出待检测者的疾病分类预测标签。




图 1




图 2




图 3




图 4




图 5




图 6




图 7

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2019/125430

A. CLASSIFICATION OF SUBJECT MATTER

G16H 30/20(2018.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G16H; G06T

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

WPI; EPODOC; CNKI; CNPAT: 生成对抗网络, 训练, 标签, 图像, 影像, 分类器, 合成, 转化, MRI, PET, CT, GAN, train, label, image, classifier, transform

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	CN 109523584 A (SHANGHAI UNITED IMAGING HEALTHCARE CO., LTD.) 26 March 2019 (2019-03-26) description, paragraphs [0066]-[0068], [0076]-[0081], [0098]	1-11
A	CN 109035356 A (SICHUAN UNIVERSITY) 18 December 2018 (2018-12-18) entire document	1-11
A	WO 2019051227 A1 (THE GENERAL HOSPITAL CORPORATION) 14 March 2019 (2019-03-14) entire document	1-11



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

12 April 2020

Date of mailing of the international search report

07 May 2020

Name and mailing address of the ISA/CN

China National Intellectual Property Administration (ISA/
CN)
No. 6, Xitucheng Road, Jimenqiao Haidian District, Beijing
100088
China

Authorized officer

Facsimile No. (86-10)62019451

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2019/125430

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)	Publication date (day/month/year)
CN	109523584	A	26 March 2019	None	
CN	109035356	A	18 December 2018	None	
WO	2019051227	A1	14 March 2019	None	

国际检索报告

国际申请号

PCT/CN2019/125430

A. 主题的分类

G16H 30/20(2018.01)i

按照国际专利分类(IPC)或者同时按照国家分类和IPC两种分类

B. 检索领域

检索的最低限度文献(标明分类系统和分类号)

G16H; G06T

包含在检索领域中的除最低限度文献以外的检索文献

在国际检索时查阅的电子数据库(数据库的名称, 和使用的检索词(如使用))

WPI;EPDOC;CNKI;CNPAT: 生成对抗网络, 训练, 标签, 图像, 影像, 分类器, 合成, 转化, MRI, PET, CT, GAN, train, label, image, classifier, transform

C. 相关文件

类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
A	CN 109523584 A (上海联影医疗科技有限公司) 2019年 3月 26日 (2019 - 03 - 26) 说明书第[0066]-[0068], [0076]-[0081], [0098]段	1-11
A	CN 109035356 A (四川大学) 2018年 12月 18日 (2018 - 12 - 18) 全文	1-11
A	WO 2019051227 A1 (THE GENERAL HOSPITAL CORPORATION) 2019年 3月 14日 (2019 - 03 - 14) 全文	1-11

☐ 其余文件在C栏的续页中列出。☒ 见同族专利附件。

* 引用文件的具体类型:

“A” 认为不特别相关的表示了现有技术一般状态的文件

“E” 在国际申请日的当天或之后公布的在先申请或专利

“L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件(如具体说明的)

“O” 涉及口头公开、使用、展览或其他方式公开的文件

“P” 公布日先于国际申请日但迟于所要求的优先权日的文件

“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件

“X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性

“Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性

“&” 同族专利的文件

国际检索实际完成的日期

2020年 4月 12日

国际检索报告邮寄日期

2020年 5月 7日

ISA/CN的名称和邮寄地址

中国国家知识产权局(ISA/CN)

中国北京市海淀区蓟门桥西土城路6号 100088

传真号 (86-10)62019451

授权官员

庄湧

电话号码 86-(10)-53961296

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2019/125430

检索报告引用的专利文件			公布日 (年/月/日)	同族专利	公布日 (年/月/日)
CN	109523584	A	2019年 3月 26日	无	
CN	109035356	A	2018年 12月 18日	无	
WO	2019051227	A1	2019年 3月 14日	无	