



## (12) 发明专利申请

(10) 申请公布号 CN 120197543 A

(43) 申请公布日 2025.06.24

(21) 申请号 202510252935.7

G06F 119/14 (2020.01)

(22) 申请日 2025.03.05

(71) 申请人 江苏大学附属医院

地址 212000 江苏省镇江市解放路438号

(72) 发明人 陈艳 倪益益

(74) 专利代理机构 北京领时辉专利代理事务所  
(普通合伙) 33330

专利代理人 胡倩

(51) Int.Cl.

G06F 30/28 (2020.01)

A61B 5/03 (2006.01)

A61B 5/145 (2006.01)

A61B 5/00 (2006.01)

G06N 3/04 (2023.01)

G06F 113/08 (2020.01)

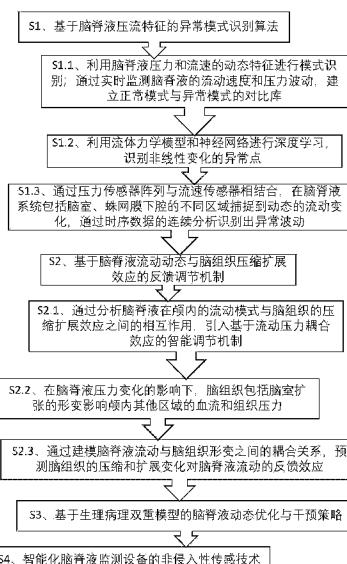
权利要求书3页 说明书13页 附图3页

(54) 发明名称

脑脊液动态监测管理方法

(57) 摘要

本发明涉及脑脊液动态监测管理方法。包括以下内容：利用脑脊液压力和流速的动态特征进行模式识别；通过实时监测脑脊液的流动速度和压力波动，建立正常模式与异常模式的对比库；利用流体力学模型和神经网络进行深度学习，识别非线性变化的异常点；通过压力传感器阵列与流速传感器相结合，在脑脊液系统包括脑室、蛛网膜下腔的不同区域捕捉到动态的流动变化，通过时序数据的连续分析识别出异常波动；通过分析脑脊液在颅内的流动模式与脑组织的压缩扩展效应之间的相互作用，引入基于流动压力耦合效应的智能调节机制；在脑脊液压力变化的影响下，脑组织包括脑室扩张的形变影响颅内其他区域的血流和组织压力。



1. 脑脊液动态监测管理方法,其特征在于包括以下步骤:

S1、基于脑脊液压流特征的异常模式识别算法:

S1.1、利用脑脊液压力和流速的动态特征进行模式识别;通过实时监测脑脊液的流动速度和压力波动,建立正常模式与异常模式的对比库;

S1.2、利用流体力学模型和神经网络进行深度学习,识别非线性变化的异常点;

S1.3、通过压力传感器阵列与流速传感器相结合,在脑脊液系统包括脑室、蛛网膜下腔的不同区域捕捉到动态的流动变化,通过时序数据的连续分析识别出异常波动;

S2、基于脑脊液流动动态与脑组织压缩扩展效应的反馈调节机制:

S2.1、通过分析脑脊液在颅内的流动模式与脑组织的压缩扩展效应之间的相互作用,引入基于流动压力耦合效应的智能调节机制;

S2.2、在脑脊液压力变化的影响下,脑组织包括脑室扩张的形变影响颅内其他区域的血流和组织压力;

S2.3、通过建模脑脊液流动与脑组织形变之间的耦合关系,预测脑组织的压缩和扩展变化对脑脊液流动的反馈效应;

S3、基于生理病理双重模型的脑脊液动态优化与干预策略:

S3.1、通过构建脑脊液流动的生理模型与病理模型的双重融合,进行脑脊液动态优化与干预;生理模型基于健康状态下的正常脑脊液流动模式,病理模型则基于包括脑积水、脑脊液漏的不同脑部疾病的脑脊液异常流动模式;

S3.2、所述生理模型反映健康人群的脑脊液流动特征,而病理模型则根据患者具体的疾病背景进行调整;通过这两者的结合,识别不同类型的脑脊液异常。

2. 根据权利要求1所述的脑脊液动态监测管理方法,其特征在于所述基于脑脊液压流特征的异常模式识别算法的实现方法包括:

通过压力传感器测量脑室内的压力波动,同时结合流速传感器检测脑脊液在同一区域内的流动速度,提供有关流动状态的动态信息;通过多维度、多点监测,实时计算脑脊液流动的不同区域、不同时间的变化;而描述脑脊液流动的状态,结合压力与流速数据,采用复合流动状态函数 $f_{flow}(t)$ ,其中:

$$f_{flow}(t) = \int_{\Omega} [\rho \cdot v(t, x) + P(t, x)] dx$$

其中:

$f_{flow}(t)$  表示脑脊液流动的综合状态,随时间 $t$ 变化,计算流速与压力的综合效应; $\Omega$  表示监测区域,包括脑室、蛛网膜下腔不同的脑脊液流动区域;积分区域 $\Omega$  跨越空间维度,捕捉整个脑脊液流动系统中的多点数据; $\rho$  表示脑脊液的密度; $v(t, x)$  表示脑脊液流速,随时间 $t$ 和空间位置 $x$ 变化;反映脑脊液的流动速度及方向; $P(t, x)$  表示在位置 $x$ 和时间 $t$ 时的脑脊液压力,反映流动状态下的局部压力差异。

3. 根据权利要求2所述的脑脊液动态监测管理方法,其特征在于所述基于脑脊液压流特征的异常模式识别算法的实现方法包括:

采用动态建模技术对连续的压力和流速数据进行分析,从中计算出脑脊液流动的规律性;而脑脊液流动的动态建模与异常波动的识别,采用自适应信号处理公式:

$$\mathcal{A}_{\text{aatv}}(t) = \frac{1}{\alpha} \sum_{i=1}^n (|P(t_i)P(t_{i-1})| + |v(t_i)v(t_{i-1})|)$$

其中：

$\mathcal{A}_{\text{aatv}}(t)$  表示脑脊液流动状态的异常度指标，在时间 t 的连续数据中识别出压力或流速的异常波动； $P(t_i)$  和  $v(t_i)$  分别表示第 i 时刻的压力和流速数据；每个  $t_i$  对应于单位时间点，记录下该时刻的监测数据； $\alpha$  为自适应参数，用于调整不同时间步长下数据的权重；根据数据的波动性来动态调节，避免噪声干扰； $|P(t_i)P(t_{i-1})|$  和  $|v(t_i)v(t_{i-1})|$  为分别表示连续时间步长内压力和流速的绝对变化量；通过计算差值，捕捉到流动状态的急剧波动，识别出异常情况。

4. 根据权利要求3所述的脑脊液动态监测管理方法，其特征在于所述基于脑脊液压流特征的异常模式识别算法的实现方法包括：

通过引入智能诊断算法，实时检测脑脊液流动中的异常波动，并给出诊断结果；结合实时流速与压力数据，判断是否存在脑积水或其他脑脊液循环障碍，并根据识别的异常模式，提出进一步干预措施。

5. 根据权利要求1所述的脑脊液动态监测管理方法，其特征在于所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括：

通过多维度建模引入多个变量，并利用深度学习算法进行优化，模拟健康状态下的流动模式，并且自适应调整以应对包括脑积水、脑脊液漏的病理状态；计算脑脊液流动的特征，利用改进的 Navier-Stokes 方程，通过考虑流速、压力以及脑脊液的密度、局部阻力因素，全面模拟流动过程；

$$\frac{\partial u(x, t)}{\partial t} + (u(x, t) \cdot \nabla) u = -\frac{1}{\rho} \nabla p + \mu \nabla^2 u + f(x, t)$$

其中：

$u(x, t)$  表示脑脊液流速的向量， $x$  为空间位置， $t$  为时间；流速的大小和方向决定脑脊液的运动状态； $p$  为脑脊液的压力，描述流动中的力学变化； $\rho$  为脑脊液的密度，影响流动的惯性特性； $\mu$  为脑脊液的粘度，控制流动的阻力； $f(x, t)$  为外部作用力，反映脑脊液的生成、吸收生理过程。

6. 根据权利要求5所述的脑脊液动态监测管理方法，其特征在于所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括：通过生理模型与病理模型的结合，在健康状态与病理状态之间切换，并实时优化脑脊液流动状态的干预；生理模型基于正常个体的脑脊液流动状态，而病理模型则针对脑积水、脑脊液漏异常状态进行建模。

7. 根据权利要求6所述的脑脊液动态监测管理方法，其特征在于所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括：

通过多种传感器的数据融合，包括压力传感器、流速传感器、温度传感器，综合获得脑脊液流动的全方位信息；通过改进的卡尔曼滤波算法，消除噪声并提取特征，基于实时数据提供智能反馈；改进的卡尔曼滤波通过以下递推公式不断优化状态估计；

$$x_{t+1} = Ax_t + Bu_t + w_t$$

$$y_t = Hx_t + v_t$$

其中：

$x_t$ 为时刻t的脑脊液状态向量,包含流速、压力信息;A为状态转移矩阵,表示从时间t到t+1的状态变化,反映脑脊液流动的物理规律;B为控制输入矩阵, $u_t$ 为控制输入; $w_t$ 为过程噪声,表示流动过程中的随机扰动; $y_t$ 为来自传感器的观测数据;H为测量矩阵,表示传感器反映脑脊液状态, $v_t$ 为观测噪声。

## 脑脊液动态监测管理方法

### 技术领域

[0001] 本发明涉及脑脊液动态监测管理方法。

### 背景技术

[0002] 目前用于脑脊液动态监测管理的方法在临床应用中虽取得了一定的进展,但仍存在诸多不足和弊端,限制了其在临床实践中的广泛应用和效果提升。首先,现有的脑脊液监测方法大多依赖于传统的压力传感器和流速传感器,这些设备虽然能提供一些基本的监测数据,但其数据采集范围和精度有限,难以全面、实时地反映脑脊液流动的动态特征。例如,现有的压力传感器往往只能监测单一位置的脑脊液压力变化,无法准确捕捉到整个脑脊液系统(包括脑室、蛛网膜下腔等区域)的变化。此外,流速传感器虽能提供流速数据,但其传感精度和时间分辨率常常不能满足脑脊液流动的细致分析要求,尤其是在高速或复杂的流动模式下,容易受到噪声干扰和测量误差的影响。

[0003] 其次,现有方法对脑脊液流动的多维度特征缺乏全面的建模和动态优化处理,大多数监测系统仅依赖压力和流速数据进行简单的定量分析,忽视了脑脊液流动过程中的非线性变化以及与脑组织形变、血流等因素的相互作用,导致无法精确反映脑脊液流动状态的复杂性。这些不足使得传统脑脊液监测系统在识别病理性异常(如脑积水、脑脊液漏等)时存在较大局限,难以做到早期预警和精准干预。再次,现有的脑脊液流动监测方法大多数依赖于静态的阈值判断,如设定某一压力或流速值作为异常判定标准,而这些阈值通常是基于统计数据或单一案例经验进行设置的,缺乏针对个体差异的个性化调整。这使得在处理脑脊液异常时,难以做到精准的个性化诊疗,容易导致误判和漏诊,特别是在一些复杂病理状态下,传统方法往往难以及时发现潜在的异常变化。更重要的是,目前很多脑脊液监测系统的实时性差,无法动态调整监测和干预策略。由于脑脊液流动状态受多种因素的影响,如脑室形态、脑组织的弹性、血流动力学等,流动状态是一个高度动态的过程,而现有技术大多依赖静态的生理模型和单一的检测方式,缺乏足够的灵活性和适应性,不能实时跟踪患者状态的变化,导致治疗策略的滞后性和不足。

[0004] 另一方面,现有脑脊液监测技术中,大部分系统缺乏充分的数据融合与智能诊断功能,导致在多点、多维度监测时,难以实现各项数据的有效整合。脑脊液流动的状态不仅与压力和流速相关,还与温度、密度、局部阻力等多个参数紧密相连,这些变量相互作用,形成复杂的流动模式。然而,现有的传感器多依赖单一的监测数据,如压力传感器或流速传感器,这使得监测结果缺乏全面性和深度,难以捕捉到多种参数交互作用下的微小变化。缺乏有效的数据融合与智能化分析,导致系统对异常模式的识别能力有限,无法像人类专家那样进行综合判断。此外,传统的脑脊液监测技术中,大多数设备仍需依赖人工干预进行数据解读和诊断,缺乏足够的智能化诊断功能。

### 发明内容

[0005] 本发明的目的是提供脑脊液动态监测管理方法,从而解决背景技术中所指出的部

分弊端和不足。

[0006] 本发明解决其上述的技术问题所采用以下的技术方案包括以下步骤：

[0007] S1、基于脑脊液压流特征的异常模式识别算法：

[0008] S1.1、利用脑脊液压力和流速的动态特征进行模式识别；通过实时监测脑脊液的流动速度和压力波动，建立正常模式与异常模式的对比库；

[0009] S1.2、利用流体力学模型和神经网络进行深度学习，识别非线性变化的异常点；

[0010] S1.3、通过压力传感器阵列与流速传感器相结合，在脑脊液系统包括脑室、蛛网膜下腔的不同区域捕捉到动态的流动变化，通过时序数据的连续分析识别出异常波动；

[0011] S2、基于脑脊液流动动态与脑组织压缩扩展效应的反馈调节机制：

[0012] S2.1、通过分析脑脊液在颅内的流动模式与脑组织的压缩扩展效应之间的相互作用，引入基于流动压力耦合效应的智能调节机制；

[0013] S2.2、在脑脊液压力变化的影响下，脑组织包括脑室扩张的形变影响颅内其他区域的血流和组织压力；

[0014] S2.3、通过建模脑脊液流动与脑组织形变之间的耦合关系，预测脑组织的压缩和扩展变化对脑脊液流动的反馈效应；

[0015] S3、基于生理病理双重模型的脑脊液动态优化与干预策略：

[0016] S3.1、通过构建脑脊液流动的生理模型与病理模型的双重融合，进行脑脊液动态优化与干预；生理模型基于健康状态下的正常脑脊液流动模式，病理模型则基于包括脑积水、脑脊液漏的不同脑部疾病的脑脊液异常流动模式；

[0017] S3.2、所述生理模型反映健康人群的脑脊液流动特征，而病理模型则根据患者具体的疾病背景进行调整；通过这两者的结合，识别不同类型的脑脊液异常；

[0018] S4、智能化脑脊液监测设备的非侵入性传感技术：

[0019] S4.1、开发非侵入性的智能监测设备，采用传感器技术在不直接接触脑脊液的情况下监测脑脊液的动态变化；通过传感器设备测量颅内压力、脑脊液流动速率以及脑组织的形变信息。

[0020] 进一步地，所述基于脑脊液压流特征的异常模式识别算法的实现方法包括：

[0021] 通过压力传感器测量脑室内的压力波动，同时结合流速传感器检测脑脊液在同一区域内的流动速度，提供有关流动状态的动态信息；通过多维度、多点监测，实时计算脑脊液流动的不同区域、不同时间的变化；而描述脑脊液流动的状态，结合压力与流速数据，采用复合流动状态函数 $f_{flow}(t)$ ，其中：

[0022]  $f_{flow}(t) = \int_{\Omega} [\rho \cdot v(t, x) + P(t, x)] dx$

[0023] 其中：

[0024]  $f_{flow}(t)$  表示脑脊液流动的综合状态，随时间 $t$ 变化，计算流速与压力的综合效应； $\Omega$  表示监测区域，包括脑室、蛛网膜下腔不同的脑脊液流动区域；积分区域 $\Omega$  跨越空间维度，捕捉整个脑脊液流动系统中的多点数据； $\rho$  表示脑脊液的密度； $v(t, x)$  表示脑脊液流速，随时间 $t$ 和空间位置 $x$ 变化；反映脑脊液的流动速度及方向； $P(t, x)$  表示在位置 $x$ 和时间 $t$ 时的脑脊液压力，反映流动状态下的局部压力差异。

[0025] 进一步地，所述基于脑脊液压流特征的异常模式识别算法的实现方法包括：

[0026] 采用动态建模技术对连续的压力和流速数据进行分析，从中计算出脑脊液流动的

规律性;而脑脊液流动的动态建模与异常波动的识别,采用自适应信号处理公式:

$$[0027] \quad \mathcal{A}_{\text{aatv}}(t) = \frac{1}{\alpha} \sum_{i=1}^n (|P(t_i)P(t_{i-1})| + |v(t_i)v(t_{i-1})|)$$

[0028] 其中:

[0029]  $\mathcal{A}_{\text{aatv}}(t)$ 表示脑脊液流动状态的异常度指标,在时间t的连续数据中识别出压力或流速的异常波动; $P(t_i)$ 和 $v(t_i)$ 分别表示第*i*时刻的压力和流速数据;每个 $t_i$ 对应于单位时间点,记录下该时刻的监测数据; $\alpha$ 为自适应参数,用于调整不同时间步长下数据的权重;根据数据的波动性来动态调节,避免噪声干扰; $|P(t_i)P(t_{i-1})|$ 和 $|v(t_i)v(t_{i-1})|$ 为分别表示连续时间步长内压力和流速的绝对变化量;通过计算差值,捕捉到流动状态的急剧波动,识别出异常情况。

[0030] 进一步地,所述基于脑脊液压流特征的异常模式识别算法的实现方法包括:

[0031] 通过引入智能诊断算法,实时检测脑脊液流动中的异常波动,并给出诊断结果;结合实时流速与压力数据,判断是否存在脑积水或其他脑脊液循环障碍,并根据识别的异常模式,提出进一步干预措施;而数据融合过程通过以下公式表示:

$$[0032] \quad D_{\text{fusion}}(t) = \sum_{k=1}^K [\lambda_k \cdot f_k(t)]$$

[0033] 其中:

[0034]  $D_{\text{fusion}}(t)$ 表示通过数据融合得到的综合状态评估,反映多个监测区域的脑脊液流动综合状态; $\lambda_k$ 表示第*k*个传感器数据的权重系数,用于表示每个传感器在整体诊断中的重要性; $f_k(t)$ 表示第*k*个传感器在时刻*t*输出的监测数据,包括压力数据、流速数据,反映各传感器所在位置的局部脑脊液流动状态;*K*表示传感器的总数,涵盖所有监测点的数据。

[0035] 进一步地,所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括:

[0036] 通过多维度建模引入多个变量,并利用深度学习算法进行优化,模拟健康状态下的流动模式,并且自适应调整以应对包括脑积水、脑脊液漏的病理状态;计算脑脊液流动的特征,利用改进的Navier-Stokes方程,通过考虑流速、压力以及脑脊液的密度、局部阻力因素,全面模拟流动过程;

$$[0037] \quad \frac{\partial u(x, t)}{\partial t} + (u(x, t) \cdot \nabla) u = -\frac{1}{\rho} \nabla p + \mu \nabla^2 u + f(x, t)$$

[0038] 其中:

[0039]  $u(x, t)$ 表示脑脊液流速的向量, $x$ 为空间位置, $t$ 为时间;流速的大小和方向决定脑脊液的运动状态; $p$ 为脑脊液的压力,描述流动中的力学变化; $\rho$ 为脑脊液的密度,影响流动的惯性特性; $\mu$ 为脑脊液的粘度,控制流动的阻力; $f(x, t)$ 为外部作用力,反映脑脊液的生成、吸收生理过程。

[0040] 进一步地,所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括:

[0041] 通过生理模型与病理模型的结合,在健康状态与病理状态之间切换,并实时优化脑脊液流动状态的干预;生理模型基于正常个体的脑脊液流动状态,而病理模型则针对脑积水、脑脊液漏异常状态进行建模;而生理与病理模型的实时融合使用变分法来优化模型,

通过最小化模型预测误差和参考模型之间的差异,根据实时数据动态调整干预策略:

$$[0042] \quad \min_{M_t} \left( \sum_{i=1}^N (u_i^{\text{pred}} - u_i^{\text{true}})^2 + \lambda_1 \int_V (\nabla^2 M)^2 dV + \lambda_2 \int_0^T |M_t - M_{\text{ref}}|^2 dt \right)$$

[0043] 其中:

[0044]  $M_t$  表示时刻t的脑脊液状态模型,包含流速、压力信息;  $u_i^{\text{pred}}$  为预测的流速值,  $u_i^{\text{true}}$  为实际测量的流速值;  $\nabla^2 M$  为模型的二阶空间导数,描述流动的曲率变化,用来捕捉脑脊液流动的微小变化;  $M_{\text{ref}}$  为健康状态下的参考模型,作为模型调整的基准;  $\lambda_1, \lambda_2$  为正则化系数,用来平衡预测误差和模型复杂度。

[0045] 进一步地,所述基于生理病理双重模型的脑脊液动态优化与干预策略方法包括:

[0046] 通过多种传感器的数据融合,包括压力传感器、流速传感器、温度传感器,综合获得脑脊液流动的全方位信息;通过改进的卡尔曼滤波算法,消除噪声并提取特征,基于实时数据提供智能反馈;改进的卡尔曼滤波通过以下递推公式不断优化状态估计;

$$[0047] \quad x_{t+1} = Ax_t + Bu_t + w_t$$

$$[0048] \quad y_t = Hx_t + v_t$$

[0049] 其中:

[0050]  $x_t$  为时刻t的脑脊液状态向量,包含流速、压力信息;A为状态转移矩阵,表示从时间t到t+1的状态变化,反映脑脊液流动的物理规律;B为控制输入矩阵,  $u_t$  为控制输入;  $w_t$  为过程噪声,表示流动过程中的随机扰动;  $y_t$  为来自传感器的观测数据;H为测量矩阵,表示传感器反映脑脊液状态,  $v_t$  为观测噪声。

[0051] 本发明的脑脊液动态监测管理方法,通过综合运用传感器技术、流体力学建模、智能算法与深度学习等手段,具有以下显著的有益效果:

[0052] 实时、全面地监测脑脊液的流速、压力、温度等动态变化,并通过传感器的多维度数据融合,消除单一传感器的噪声干扰,确保数据的准确性和可靠性。这种精准的监测为医生提供了全面的脑脊液流动状态,帮助及时发现潜在的异常波动,避免病情的进一步恶化。通过基于脑脊液压力与流速特征的异常模式识别算法,可以在动态监测中捕捉到脑脊液流动的非线性变化,识别脑积水、脑脊液漏等病理状态。该方法通过多点监测、时序数据分析,准确识别脑脊液流动的异常模式,做到早期预警,为患者提供及时干预的机会。

[0053] 结合生理与病理双重模型,本发明能够根据实时数据动态调整干预策略,从而优化脑脊液流动状态。通过使用变分法优化模型、深度学习算法的自适应调整功能,能够精确模拟和预测健康与病理状态下的脑脊液流动模式,针对不同病理状态(如脑积水、脑脊液漏)采取个性化的干预措施,提升治疗效果。采用非侵入性智能监测设备,通过传感器实时获取脑脊液流动状态,而无需对患者进行创伤性操作。结合智能诊断算法,系统能够分析数据并提供诊断建议,减轻医生的工作负担,提高诊断效率,降低人为误差。

## 附图说明

[0054] 图1为本发明脑脊液动态监测管理方法流程图。

[0055] 图2为本发明基于脑脊液压流特征的异常模式识别算法的实现方法的流程图。

[0056] 图3为本发明基于生理病理双重模型的脑脊液动态优化与干预策略方法的流程

图。

## 具体实施方式

[0057] 下面结合附图对本发明的具体实施方式做一个详细的说明。

[0058] 脑脊液动态监测管理方法通过全面结合脑脊液流动的多维度特征、先进的传感技术和深度学习算法，旨在实时识别和预测脑脊液流动的异常波动，并通过动态优化干预措施，以提高脑脊液管理的精准性和个性化。首先，方法的核心是通过监测脑脊液的压力和流速的动态变化，这两个物理量能充分反映脑脊液在不同区域的流动状态。传统的脑脊液监测主要依赖压力传感器，通过简单的压力数值监测判断脑脊液流动的正常与异常，但这种方法往往无法提供关于流动速度、方向和流动模式的全面信息，因此，现有技术存在一定的局限性。该方法通过结合压力传感器阵列与流速传感器阵列，能够同时捕捉脑脊液流速和压力的实时变化，为监测提供更加立体和细致的数据支持。

[0059] 为了实现准确的脑脊液动态监测，首先需要建立正常模式与异常模式的对比库。在这个对比库中，正常模式包括健康个体在不同生理条件下的脑脊液流动状态，而异常模式则主要集中在脑脊液流动出现异常波动的情况，如脑积水、脑脊液漏等病理变化。通过对对比库的建立，可以为系统提供一个基准，帮助区分哪些流动模式属于正常范围，哪些属于潜在的异常。在此基础上，通过流体力学模型和神经网络的结合，进一步提升对脑脊液流动状态的理解和预测能力。流体力学模型可为脑脊液流动提供基础的物理模型，描述流体在脑脊液系统中的流动规律，包括压力分布、流速、局部阻力等因素。这些物理因素为识别脑脊液异常波动提供了基础框架。而神经网络则通过深度学习算法，能够学习到脑脊液流动中的复杂模式，尤其是非线性的变化，识别出那些常规物理模型难以捕捉的异常点。例如，神经网络可以通过大量历史数据的学习，发现一些微小的变化，如局部压力的突变、流速的突然降低等，从而为早期预警提供依据。

[0060] 结合多种传感器数据进行动态监测，方法进一步加强了脑脊液流动状态的捕捉精度。通过压力传感器阵列与流速传感器的联合部署，可以在脑室、蛛网膜下腔等不同区域同时监测脑脊液流动的压力和流速变化，进而获得脑脊液系统在不同部位的多维度流动信息。这种多点、多维度的监测方式能够更全面地反映脑脊液流动的状态，不仅能识别出整体流动的变化，还能够捕捉到局部的异常波动。这些数据通过时序分析进一步处理，能够为实时监测提供精确的变化趋势，通过历史数据的积累，分析脑脊液流动的长期演变模式，从而有效识别出异常波动。

[0061] 脑脊液不仅仅是一种充当脑室系统和脊髓腔隙之间缓冲和营养输送的液体，它的流动模式还直接影响颅内的压力分布、脑组织的形变以及血流的状态。当脑脊液的流动状态发生变化时，脑脊液的压力波动不仅影响脑组织的形态（如脑室的扩张或收缩），还会影响到周围脑组织的压缩或扩展，进而改变脑血流的动力学特性和组织内的局部压力。因此，脑脊液与脑组织之间存在一个动态耦合的关系，这一关系需要通过精确建模和实时监控来捕捉并加以调节。传统的脑脊液监测技术通常仅关注脑脊液的流速和压力，而忽略了脑组织的形变效应，这在某些情况下导致了监测效果的不足和病理诊断的滞后。

[0062] 在这种情况下，脑脊液压力的变化成为了关键因素。随着脑脊液压力的波动，脑组织，尤其是脑室系统，发生扩张或收缩，这种形变作用不仅影响局部脑组织的几何结构，还

影响颅内其他区域的血流和组织压力。例如,在脑积水等病理状态下,脑室的扩张导致周围脑组织的压缩,进而对颅内血流造成压迫或阻力的变化。脑脊液流动压力和脑组织形变之间的相互作用会通过复杂的物理与生理机制反馈回脑脊液流动本身。这种双向反馈效应对意味着,脑脊液的流动状态不仅会影响脑组织形变,同时脑组织的压缩和扩展也会对脑脊液的流动产生反向影响,导致脑脊液的流动特性发生变化。因此,理解这种耦合关系并在此基础上进行智能调节,成为了精准脑脊液管理的核心。

[0063] 为此,该方法通过建模脑脊液流动与脑组织形变之间的耦合关系,实现了对颅内复杂动态状态的全面把握。首先,脑脊液流动过程可以用流体力学模型来描述,考虑脑脊液的流速、压力、流动方向等因素。与此相对,脑组织形变则涉及到生物力学模型,重点描述脑组织在不同压力作用下的弹性和可塑性。通过将这两者结合起来,可以建立一个包括流动、形变、血流和组织压力的综合动态模型。该模型能够预测脑组织的压缩和扩展对脑脊液流动的反馈效应,从而精确模拟颅内的压力变化。比如,若某一区域的脑室扩张导致脑组织局部压缩,这种形变效应将直接影响脑脊液在该区域的流动情况,会引起局部流速的变化或脑脊液压力的波动。通过对这些因素的实时监测与计算,系统能够识别脑脊液流动与脑组织形变之间的复杂相互作用,并据此调节脑脊液的流动状态,避免因压力不平衡而导致的病理变化进一步恶化。

[0064] 在此基础上,基于流动压力耦合效应的智能调节机制被提出。这一机制通过实时采集脑脊液的压力和流速数据,同时监测脑组织的形变效应和局部血流状态,将所有数据输入至智能算法中进行分析。系统不仅能够识别脑脊液流动中的异常波动,还能够通过反馈控制调节脑脊液的流动状态。例如,当脑室扩张导致某一区域的脑脊液压力过高时,智能调节机制能够调整流速,减少脑脊液压力过高的区域,进而恢复压力平衡并避免对脑组织的进一步压迫或损伤。通过这种基于耦合效应的调节机制,系统能够在不同的生理或病理状态下实现实时、精确的干预,保证脑脊液的流动和脑组织的健康。

[0065] 生理模型反映的是健康个体脑脊液流动的正常模式,它主要包括脑脊液的流动速度、压力分布、生成与吸收速率等特征,这些特征在健康人群中呈现出稳定、规律的模式。生理模型通过数学建模和流体力学原理,模拟出正常情况下脑脊液在脑室、蛛网膜下腔及脊髓等区域的流动状态。这一模型提供了脑脊液流动的基准数据,用于监测健康状态下的变化趋势。病理模型则是针对不同类型的脑部疾病,如脑积水、脑脊液漏、颅内压增高等病理状态,调整和重新构建的流动模型。病理模型反映的是在疾病情况下脑脊液流动的异常特征,比如脑积水时脑室扩张导致的脑脊液滞留,或脑脊液漏引起的流动失常等,这些异常会导致脑脊液的流动模式偏离正常状态。通过建立和优化这些病理模型,能够识别出不同疾病状态下的脑脊液流动变化,并为相应的干预提供数据支持。生理模型与病理模型的双重融合不仅能够精准反映正常与异常脑脊液流动模式之间的差异,还能够通过对比分析,帮助识别患者具体的脑脊液异常情况。通过这种双重模型的结合,可以在动态监测过程中根据患者的实时数据不断调整优化策略,以便对不同类型的脑脊液异常进行精确干预。例如,当脑脊液流动出现异常波动时,系统能够根据病理模型的预测结果,判断是否为脑积水、脑脊液漏或其他病理变化,并调节优化方案来恢复正常脑脊液流动状态,进而改善患者的健康状况。

[0066] 传统的脑脊液监测方法往往需要通过侵入性操作,如脑室引流管或腰椎穿刺来直

接获取脑脊液数据,虽然这些方法在某些临床场景下具有必要性,但也存在感染风险、患者不适和操作难度等问题。非侵入性监测技术则突破了这一限制,利用高精度传感器设备通过表面测量实现对脑脊液流动和压力的监控,从而提供一种更加安全和便捷的解决方案。传感器技术通过采集来自颅内不同位置的数据来实时反映脑脊液的流动状态、压力波动以及脑组织的形变情况。具体来说,传感器可以部署在头皮表面或颅骨附近,采用如超声、磁共振成像(MRI)、近红外光谱(NIRS)、电磁感应或光学传感器等无创技术,通过穿透颅骨获取数据。这些传感器可以监测到颅内压力变化,并通过分析压力的时序数据来推测脑脊液的流动模式。流动速率是另一个关键指标,通过对脑脊液流速的测量,可以获得脑脊液在脑室和蛛网膜下腔中的流动状况,进而揭示脑脊液的流动阻力、循环效率等关键信息。此外,脑组织的形变信息同样可以通过无创传感器技术来获取,比如利用应变传感器或超声波技术,通过测量脑组织表面的微小位移或变形,推断出脑脊液流动对脑组织的压迫或扩展影响。这些形变数据可以结合压力和流速数据,共同描绘出脑脊液和脑组织之间的动态相互作用。通过将这些传感器收集到的数据进行实时分析和处理,智能监测系统可以通过算法模型进行多维度数据融合,识别出脑脊液流动异常的潜在风险,如脑积水、脑脊液漏等病理状态。这些信息不仅有助于监测脑脊液流动的健康状况,还能为医生提供精准的诊断依据,进而采取合适的干预措施。因此,非侵入性的智能监测设备能够在不直接接触脑脊液的情况下,提供实时的脑脊液动态变化监测,为脑脊液管理和脑部疾病诊断提供强大的支持。

[0067] 实施例1:

[0068] 实施例正在监测某名患有脑积水的患者,这种病理状态下,脑脊液在脑室内积聚,导致脑脊液流动受到影响。通过在患者的头部装置非侵入性传感器,能够实时收集压力和流速数据,并通过多点监测计算整个脑脊液系统的流动状态。

[0069] 为了便于分析,选定了脑室作为主要监测区域,结合在蛛网膜下腔等不同区域的流动情况进行全局建模。首先,设定患者的脑脊液密度 $\rho$ 约为 $1.002\text{g/cm}^3$ ,这个值在健康人群中基本一致,在脑积水的情况下由于脑室扩张,流体密度变化较小。接下来,采用流速传感器与压力传感器结合,实时监测脑脊液在脑室内的流动速度和局部压力。设定使用超声波流速传感器,在一个时间点测得脑脊液流速为 $v(t, x) = 2\text{cm/s}$ ,即脑脊液在该位置上的流动速度为每秒2厘米,同时在同一位置测得脑脊液的压力为 $P(t, x) = 150\text{mmHg}$ ,表示局部的脑脊液压力。根据上述公式,脑脊液流动状态的综合函数 $f_{flow}(t)$ 可以通过积分计算得到:

$$[0070] f_{flow}(t) = \int_{\Omega} [\rho \cdot v(t, x) + P(t, x)] dx$$

[0071] 设定选择的监测区域 $\Omega$ 是脑室内部的一个小区域,面积为 $\Delta A = 3\text{cm}^2$ ,用积分形式来近似该区域内的流动状态。通过将流速和压力的数据代入公式,计算该区域内的流动状态:

$$[0072] f_{flow}(t) = \int_{\Omega} [1.002 \cdot 2 + 150] dx = (1.002 \cdot 2 + 150) \times 3\text{cm}^2 = (2.004 + 150) \times 3$$

$$[0073] = 456.012\text{g} \cdot \text{cm/s}^2$$

[0074] 这个综合值 $f_{flow}(t) = 456.012\text{g} \cdot \text{cm/s}^2$ 为当前脑脊液流动状态的综合指标,表示在此时此地,脑脊液的流速、压力及其密度对流动状态的影响。

[0075] 接下来,通过对比健康人群和病理状态下(如脑积水)的典型数据,可以通过模式识别算法来判断是否存在异常。设定正常情况下,脑脊液的流速约为 $v(t, x) = 3\text{cm/s}$ ,而压力则为 $P(t, x) = 120\text{mmHg}$ 。在脑积水的患者中,流速降低而压力增高,表明流动阻力增大,脑

脊液滞留的风险增加。此时,通过实时分析该值并与健康状态下的参考值进行对比,算法会发现脑脊液流速降低与压力升高的异常模式,并进行预警。

[0076] 进一步地,结合多维度监测,可以根据不同区域的流速与压力数据形成一个全局视图,结合机器学习模型训练,识别出不同类型的脑脊液异常模式。例如,在本例中,设定通过多点监测发现,脑室内的多个位置的压力和流速都偏离了正常范围。通过对历史数据与当前监测数据,可以识别出潜在的脑积水风险并提前发出预警。

[0077] 在患者的脑室内,监测设备持续记录压力与流速数据,基于实时传感器反馈系统,持续采集压力和流速数据并输入算法进行处理。设定在某次监测周期内,系统测得的脑脊液压力数据分别为: $P(t_0) = 150\text{mmHg}$ , $P(t_1) = 153\text{mmHg}$ , $P(t_2) = 158\text{mmHg}$ ,以及流速数据为: $v(t_0) = 2.1\text{cm/s}$ , $v(t_1) = 2.4\text{cm/s}$ , $v(t_2) = 2.8\text{cm/s}$ 。这些数据代表在不同时间点测量到的压力与流速数值。

[0078] 为了识别异常波动,将采用自适应信号处理公式来分析连续的压力与流速数据,计算异常度指标 $\mathcal{A}_{aatv}(t)$ ,公式如下:

$$[0079] \quad \mathcal{A}_{aatv}(t) = \frac{1}{\alpha} \sum_{i=1}^n (|P(t_i) - P(t_{i-1})| + |v(t_i) - v(t_{i-1})|)$$

[0080] 其中, $\mathcal{A}_{aatv}(t)$ 表示脑脊液流动状态的异常度指标,反映了在给定时间段内压力与流速的急剧变化程度。公式中的 $P(t_i)$ 和 $v(t_i)$ 分别是第*i*时刻的压力与流速数据, $\alpha$ 是自适应参数,用于调整不同时间步长下数据的权重,避免因为噪声或波动性过大导致的误判。

[0081] 设定 $\alpha=0.5$ 作为自适应参数的初值,这一取值范围的选择根据以往的临床数据验证,其能够有效调节计算中的误差并减少由噪声引入的干扰。

[0082] 接下来,逐步代入数据,计算异常度指标 $\mathcal{A}_{aatv}(t)$ :

[0083] 计算第一个时间步长的变化量:

$$[0084] \quad |P(t_1) - P(t_0)| = |153 - 150| = 3\text{mmHg}$$

$$[0085] \quad |v(t_1) - v(t_0)| = |2.4 - 2.1| = 0.3\text{cm/s}$$

[0086] 计算第二个时间步长的变化量:

$$[0087] \quad |P(t_2) - P(t_1)| = |158 - 153| = 5\text{mmHg}$$

$$[0088] \quad |v(t_2) - v(t_1)| = |2.8 - 2.4| = 0.4\text{cm/s}$$

[0089] 将所有数据代入公式,计算出异常度指标:

$$[0090] \quad \mathcal{A}_{aatv}(t) = \frac{1}{0.5} [(3 + 0.3) + (5 + 0.4)] = \frac{1}{0.5} [3.3 + 5.4] = \frac{1}{0.5} \times 8.7 = 17.4$$

[0091] 在此情况下,异常度指标 $\mathcal{A}_{aatv}(t) = 17.4$ 表明,脑脊液流动状态出现了明显的变化,压力与流速的波动较大,反映出潜在的异常波动。此时,基于设定的阈值模型,系统会判断该值超过了正常范围,发出警报,提示的脑积水恶化风险,医生可以根据这一预警进一步评估病情或采取相应的干预措施。通过上述的自适应信号处理分析,结合压力与流速的动态变化,能够识别脑脊液流动中的潜在异常,尤其是在脑积水等疾病中,脑脊液流动的波动性通常较大,而这正是该算法的优势所在。算法中的自适应参数 $\alpha$ 的调整,也确保了在不同临床场景下的灵活性。

[0092] 为了实现全面的脑脊液流动监测,系统将实时采集这些不同区域的监测数据,并结合智能诊断算法来检测脑脊液流动中的异常波动。设定系统在某一时刻收集到如下数据:

[0093] 在脑室区域,压力传感器读取的压力数据为: $P_1(t) = 160\text{mmHg}$ ;

[0094] 在同一区域,流速传感器读取的流速数据为: $v_1(t) = 2.3\text{cm/s}$ ;

[0095] 在蛛网膜下腔区域,压力传感器读取的压力数据为: $P_2(t) = 162\text{mmHg}$ ;

[0096] 在蛛网膜下腔区域,流速传感器读取的流速数据为: $v_2(t) = 2.5\text{cm/s}$ 。

[0097] 此外,系统采用数据融合算法将多个传感器的数据进行整合,从而为最终的诊断提供更为精确的结果。数据融合过程通过以下公式来表示:

$$[0098] D_{\text{fusion}}(t) = \sum_{k=1}^K [\lambda_k \cdot f_k(t)]$$

[0099] 其中, $D_{\text{fusion}}(t)$  表示通过数据融合得到的综合状态评估,反映了多个监测区域的脑脊液流动综合状态; $\lambda_k$  表示第  $k$  个传感器数据的权重系数,用于表示每个传感器在整体诊断中的重要性; $f_k(t)$  表示第  $k$  个传感器在时刻  $t$  输出的监测数据,包括压力数据、流速数据,反映各传感器所在位置的局部脑脊液流动状态; $K$  表示传感器的总数,涵盖所有监测点的数据。

[0100] 为了说明如何应用此算法,设定系统中使用了两个传感器:第一个传感器位于脑室区域,第二个传感器位于蛛网膜下腔区域。还设定传感器的权重系数为:

[0101]  $\lambda_1 = 0.6$  (脑室区域传感器的权重较高,因其监测数据在整个诊断中占据更大比重);

[0102]  $\lambda_2 = 0.4$  (蛛网膜下腔区域传感器的权重较低,但仍然重要)。

[0103] 因此,在此时刻,数据融合公式可以写作:

$$[0104] D_{\text{fusion}}(t) = 0.6 \cdot f_1(t) + 0.4 \cdot f_2(t)$$

[0105] 在这里, $f_1(t)$  和  $f_2(t)$  分别表示第一个和第二个传感器输出的监测数据,包括压力和流速信息。为了进一步说明,可以将这些数据代入公式:

[0106] 对于第一个传感器, $f_1(t) = P_1(t) + v_1(t) = 160 + 2.3 = 162.3$ ;

[0107] 对于第二个传感器, $f_2(t) = P_2(t) + v_2(t) = 162 + 2.5 = 164.5$ 。

[0108] 代入数据融合公式:

$$[0109] D_{\text{fusion}}(t) = 0.6 \cdot 162.3 + 0.4 \cdot 164.5 = 97.38 + 65.8 = 163.18$$

[0110] 因此,经过数据融合后的综合状态评估结果为 163.18。这个综合状态评估值反映了脑脊液流动的整体健康状态。系统会根据设定的正常范围和阈值判断这个值是否偏离正常值。例如,如果系统的正常阈值设定为 150,且超过此值则认为存在异常,则诊断算法会识别到这一异常,并向医疗团队发送警报,提示的脑积水问题或其他脑脊液流动障碍。

[0111] 接下来,系统根据这一结果进一步执行智能诊断算法,判断是否需要干预。设定当前患者已经被诊断为脑积水的高风险患者,系统会依据融合后的数据和实时反馈,生成下一步的干预建议。例如,建议进行药物治疗、调整患者体位或考虑外科手术等。

[0112] 实施例2:

[0113] 某一例脑积水患者的案例中,医院为了深入研究患者的脑脊液流动状况,结合本

发明提出的基于生理病理双重模型的脑脊液动态优化与干预策略方法,使用了多维度建模技术和深度学习算法来进行脑脊液流动的精准模拟和干预。

[0114] 在此过程中,首先通过传感器采集了患者脑室和蛛网膜下腔的实时压力和流速数据,这些数据将被用于进一步建立健康状态下的流动模型和模拟患者当前脑脊液流动的异常模式。

[0115] 具体来说,患者的脑脊液流动状态首先通过使用改进的Navier-Stokes方程来描述。Navier-Stokes方程作为描述流体动力学的基础方程,在脑脊液流动的模拟中同样适用。改进的Navier-Stokes方程如下:

$$[0116] \frac{\partial u(x, t)}{\partial t} + (u(x, t) \cdot \nabla) u = -\frac{1}{\rho} \nabla p + \mu \nabla^2 u + f(x, t)$$

[0117] 在这个方程中:

[0118]  $u(x, t)$  表示脑脊液流速的向量,决定了脑脊液的运动方向和速度, $x$ 为位置, $t$ 为时间; $p$ 为脑脊液的压力,描述了流动过程中的力学变化; $\rho$ 是脑脊液的密度,这一变量影响脑脊液的惯性特性,取值范围大约为 $1000\text{kg/m}^3$ 左右; $\mu$ 为脑脊液的粘度,它控制了脑脊液流动过程中的阻力,取值大约为 $1.2 \times 10^{-3}\text{Pa} \cdot \text{s}$ ; $f(x, t)$ 表示外部作用力,主要反映了脑脊液的生成和吸收过程。

[0119] 设定患者的脑脊液在脑室区域的流速为 $u_1 = 3.5\text{cm/s}$ ,压力为 $p_1 = 150\text{mmHg}$ ,并且脑脊液的密度为 $\rho = 1000\text{kg/m}^3$ ,粘度为 $\mu = 1.2 \times 10^{-3}\text{Pa} \cdot \text{s}$ 。这些数据将代入改进后的Navier-Stokes方程,以计算脑脊液在健康状态下的流动特征。

[0120] 对于流速的变化,考虑到患者的脑脊液流动存在一定的病理变化(如脑积水引起的脑室扩张),会对原有的健康状态模型进行自适应调整。设定在病理状态下(如脑积水),脑脊液流速会减缓,设定在脑脊液流速 $u_2 = 1.5\text{cm/s}$ 的状态下,流速和压力之间的变化关系将由模型进行模拟。这时候,病理状态模型的流速和压力与健康状态模型的流速和压力之间的差异将被用于调整模型的自适应算法,以便对患者的实际病理状态进行优化。

[0121] 此时,通过深度学习算法,系统能够通过大量健康个体和病理状态的数据训练模型,识别脑脊液流动中的潜在异常模式。在这个阶段,系统会实时计算脑脊液流动的特征,结合上述改进的Navier-Stokes方程,逐步对模型进行训练与优化。

[0122] 通过模拟的流程,可以用以下的示例数据进行进一步验证。在某一时刻,模型预测到患者脑室区域的流速和压力之间的变化趋势为:

$$[0123] \frac{\partial u_1}{\partial t} + (u_1 \cdot \nabla) u_1 = -\frac{1}{\rho} \nabla p_1 + \mu \nabla^2 u_1 + f(x, t)$$

[0124] 设定此时 $u_1 = 3.5\text{cm/s}$ ,并且模型推算出的脑脊液流速 $u_2 = 1.5\text{cm/s}$ 表示流速的减缓,而压力波动为 $p_2 = 170\text{mmHg}$ ,流速的减缓和压力的增加指示着脑积水的发生。这时,深度学习模型能够通过识别这种模式,结合训练数据提出进一步的干预措施,如调整患者体位、药物干预或手术方案。因此,生理病理双重模型的应用,结合实时数据监测和深度学习算法,能够实现健康状态和病理状态之间的无缝切换,为脑脊液流动异常的精准识别和及时干预提供强有力的支持。

[0125] 本实施例在一位脑积水患者的治疗过程中,医院利用本发明提出的基于生理病理双重模型的脑脊液动态优化与干预策略方法,实现了对脑脊液流动状态的实时监控与精准

干预。该方法结合了生理与病理模型，并通过变分法优化模型预测误差，进行脑脊液流动状态的动态调整。在此过程中，首先收集了患者脑脊液的流速与压力数据，并构建了基于患者具体疾病的病理模型，同时使用正常健康个体的数据建立生理模型。

[0126] 该患者的病理状态是由于脑积水导致的脑脊液流动异常，脑室扩张明显，脑脊液流动速度明显减缓，且局部区域出现压力波动。为准确模拟并优化其脑脊液流动状态，系统首先通过健康人群的脑脊液流动状态(即生理模型)对患者的正常状态进行基准测量。然后通过变分法结合病理模型(脑积水模型)与生理模型进行实时融合，以优化脑脊液流动状态的干预策略。

[0127] 优化过程中，使用以下变分法公式进行模型优化：

$$[0128] \min_{M_t} \left( \sum_{i=1}^N (u_i^{\text{pred}} - u_i^{\text{true}})^2 + \lambda_1 \int_V (\nabla^2 M)^2 dV + \lambda_2 \int_0^T |M_t - M_{\text{ref}}|^2 dt \right)$$

[0129] 该公式的解释如下：

[0130]  $M_t$  表示时刻  $t$  的脑脊液状态模型，包含流速、压力信息，它是一个多维度的变量，随着时间变化； $u_i^{\text{pred}}$  为第  $i$  时刻预测的流速值，基于当前的模型与数据预测的脑脊液流速；

[0131]  $u_i^{\text{true}}$  为第  $i$  时刻实际测量的流速值，来自于脑脊液流速传感器； $\nabla^2 M$  为模型的二阶空间导数，它反映了脑脊液流动过程中的微小变化，描述了流动曲率的变化，帮助捕捉脑脊液流动中潜在的异常变化；

[0132]  $M_{\text{ref}}$  是健康状态下的参考模型，代表了正常脑脊液流动的标准模式，它为所有病理状态下的调整提供基准； $\lambda_1$  和  $\lambda_2$  是正则化系数，用于平衡预测误差和模型复杂度。具体来说， $\lambda_1$  控制模型的平滑程度，避免过拟合，而  $\lambda_2$  则用来平衡参考模型和实时数据之间的差异。通过将实时监测到的流速与压力数据与生理模型的标准流动状态进行比较，系统可以计算出预测流速与实际流速之间的误差，并基于此误差调整脑脊液的流动状态。进一步地，通过引入空间导数和时间积分项，优化算法能够识别并纠正脑脊液流动过程中的微小变化，确保患者的脑脊液流动恢复到最佳状态。

[0133] 在该患者的具体案例中，设定其在某一时刻的脑脊液流速预测值为  $u_{\text{pred}} = 2.0 \text{ cm/s}$ ，而实际测得流速为  $u_{\text{true}} = 1.8 \text{ cm/s}$ 。根据预测误差，系统会计算出：

$$[0134] (u_{\text{pred}} - u_{\text{true}})^2 = (2.0 - 1.8)^2 = 0.04 \text{ cm}^2/\text{s}^2$$

[0135] 同时，设定二阶空间导数项的计算值为：

$$[0136] \int_V (\nabla^2 M)^2 dV = 0.02 \text{ Pa}\cdot\text{s}^2$$

[0137] 设定参考模型与患者当前状态的差异为：

$$[0138] \int_0^T |M_t - M_{\text{ref}}|^2 dt = 0.1 \text{ Pa}\cdot\text{s}$$

[0139] 最终，优化目标的计算结果为：

$$[0140] \min_{M_t} (0.04 + \lambda_1 \cdot 0.02 + \lambda_2 \cdot 0.1)$$

[0141] 设定  $\lambda_1 = 1.0$  和  $\lambda_2 = 0.5$ ，则优化目标为：

[0142]  $\min_{M_t} (0.04 + 1.0 \cdot 0.02 + 0.5 \cdot 0.1) = 0.04 + 0.02 + 0.05 = 0.11$

[0143] 通过这一优化过程,系统能够实时调整患者的脑脊液流动状态,确保其接近正常健康状态。在干预策略的实施后,患者的脑脊液流速得到了有效改善,流动模式逐步恢复至健康状态。最终,通过连续的实时监测与反馈调整,患者的病情得到了明显的缓解,脑积水症状得到了有效控制。

[0144] 本实施例接下去医院部署了多种传感器:压力传感器用于实时监测脑脊液的压力变化,流速传感器用于捕捉脑脊液流速数据,温度传感器则用于检测脑脊液系统的温度变化。这些传感器不仅能在各个时刻获取脑脊液的流动状态,还能提供温度与压力等数据,全面反映脑脊液的流动特征。为了应对这一挑战,团队引入了改进的卡尔曼滤波算法,该算法能够有效去除传感器数据中的噪声并提取出关键信息,从而提供准确的实时状态估计。卡尔曼滤波的递推公式如下:

[0145]  $x_{t+1} = Ax_t + Bu_t + w_t$

[0146]  $y_t = Hx_t + v_t$

[0147] 其中,  $x_t$  为时刻  $t$  的脑脊液状态向量,包含了流速、压力等脑脊液的关键参数;  $A$  为状态转移矩阵,表示从时间  $t$  到  $t+1$  的状态变化,反映脑脊液流动的物理规律;  $B$  为控制输入矩阵,  $u_t$  为控制输入,表示影响脑脊液流动的外部因素,例如治疗干预;  $w_t$  为过程噪声,表示流动过程中存在的随机扰动;  $y_t$  为来自传感器的观测数据;  $H$  为测量矩阵,表示传感器如何反映脑脊液的状态;  $v_t$  为观测噪声,表示测量过程中的误差。在实施时,首先,系统会通过传感器获取脑脊液的初步数据。例如,某一时刻  $t_0$ ,流速传感器测得脑脊液流速  $v_0 = 0.8 \text{ cm/s}$ ,压力传感器测得压力值  $P_0 = 120 \text{ Pa}$ ,温度传感器则记录下温度值为  $T_0 = 37.1^\circ\text{C}$ 。这些数据通过传感器直接输入卡尔曼滤波器,算法根据已知的状态转移矩阵  $A$  和控制输入矩阵  $B$ ,结合外部输入信号(如药物干预等治疗措施),计算出当前时刻的脑脊液状态估计  $x_0$ 。

[0148] 设定状态转移矩阵  $A$  设定为:

[0149]  $A = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix}$

[0150] 其中  $\Delta t$  为时间间隔,表示每次更新时的时间步长,例如设为 0.1 秒。

[0151] 控制输入矩阵  $B$  设定为:

[0152]  $B = \begin{bmatrix} 0.5 \\ 1 \end{bmatrix}$

[0153] 控制输入  $u_t$  设定为药物输注对脑脊液流速的调节输入(例如设定为 0.2),那么更新后的状态估计公式将变为:

[0154]  $x_1 = Ax_0 + Bu_0 + w_0$

[0155]  $x_1 = \begin{bmatrix} 1 & 0.1 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0.8 \\ 120 \end{bmatrix} + \begin{bmatrix} 0.5 \\ 1 \end{bmatrix} \cdot 0.2 + w_0$

[0156] 通过卡尔曼滤波递推,系统会不断更新脑脊液流动的状态  $x_t$ ,并利用传感器的观测数据  $y_t$  来修正状态估计。例如,在某一时刻  $t_1$ ,传感器提供的数据为  $y_1 = [0.85 \text{ cm/s}, 125 \text{ Pa}, 37.2^\circ\text{C}]$ ,卡尔曼滤波会结合预测的流速、压力状态与实际测得的观测数据,进一步

优化脑脊液流动状态。

[0157] 与此同时,通过引入温度传感器的数据,温度变化也能够反映脑脊液的物理特性,例如在脑脊液循环出现异常时,温度会发生波动,从而为医生提供更加全面的诊断信息。最终,通过这一系列精确的传感器数据融合与卡尔曼滤波算法的实时优化,医院能够全面掌握患者的脑脊液动态,及时发现并应对脑脊液流动的异常波动。在该患者的脑积水治疗中,经过一段时间的干预,流速与压力逐步恢复至正常范围,脑室扩张得到有效缓解,患者的症状得到了显著改善。

[0158] 例如,在应用本方案后的第7天,患者的流速从初期的 $0.8\text{cm/s}$ 增加到了 $1.2\text{cm/s}$ ,压力从 $120\text{Pa}$ 降低至 $90\text{Pa}$ ,温度也从 $37.1^\circ\text{C}$ 稳定至 $36.8^\circ\text{C}$ ,这一系列的改善表明了脑脊液流动状态逐渐恢复,治疗干预取得了初步成功。

[0159] 通过此实例,展示了基于生理病理双重模型的脑脊液动态优化与干预策略的有效性,改进的卡尔曼滤波算法成功去除了传感器数据的噪声,提供了更为精准的脑脊液流动状态估计,并实时优化了干预策略。这种方法不仅能应对脑积水等常见病症,还能为其他脑脊液流动异常疾病提供有力的支持。

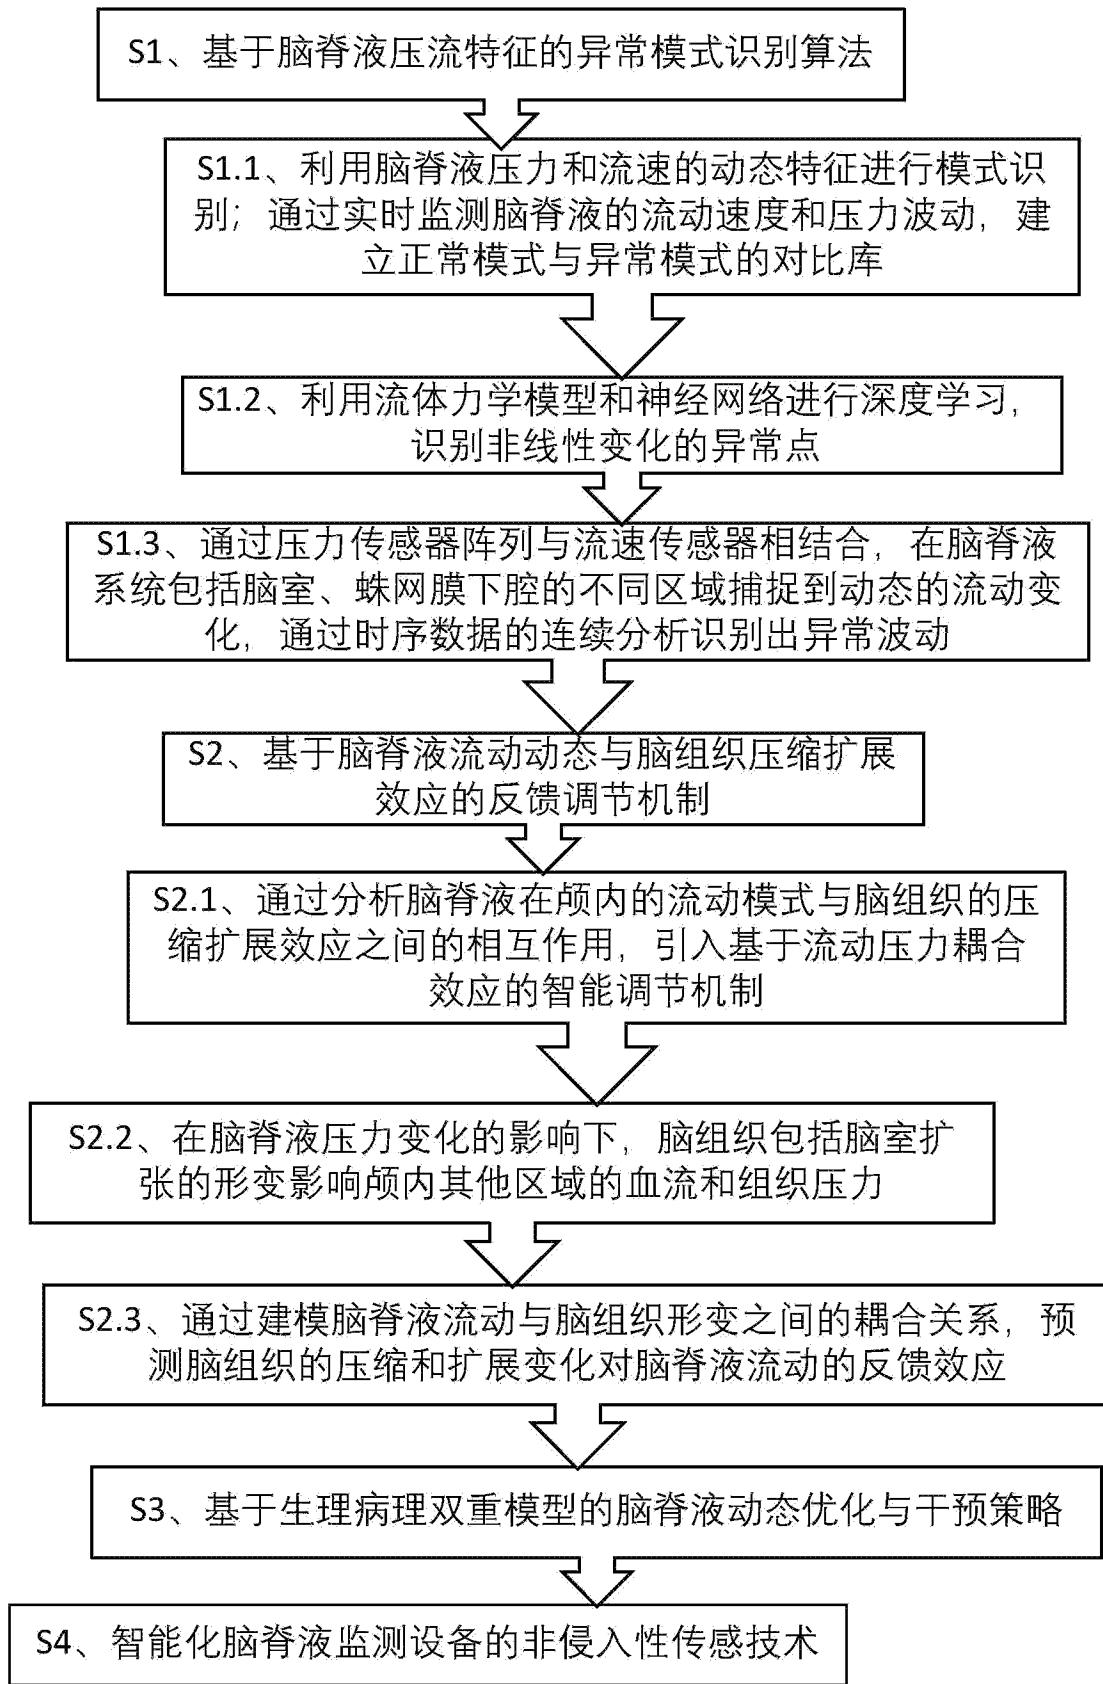


图1

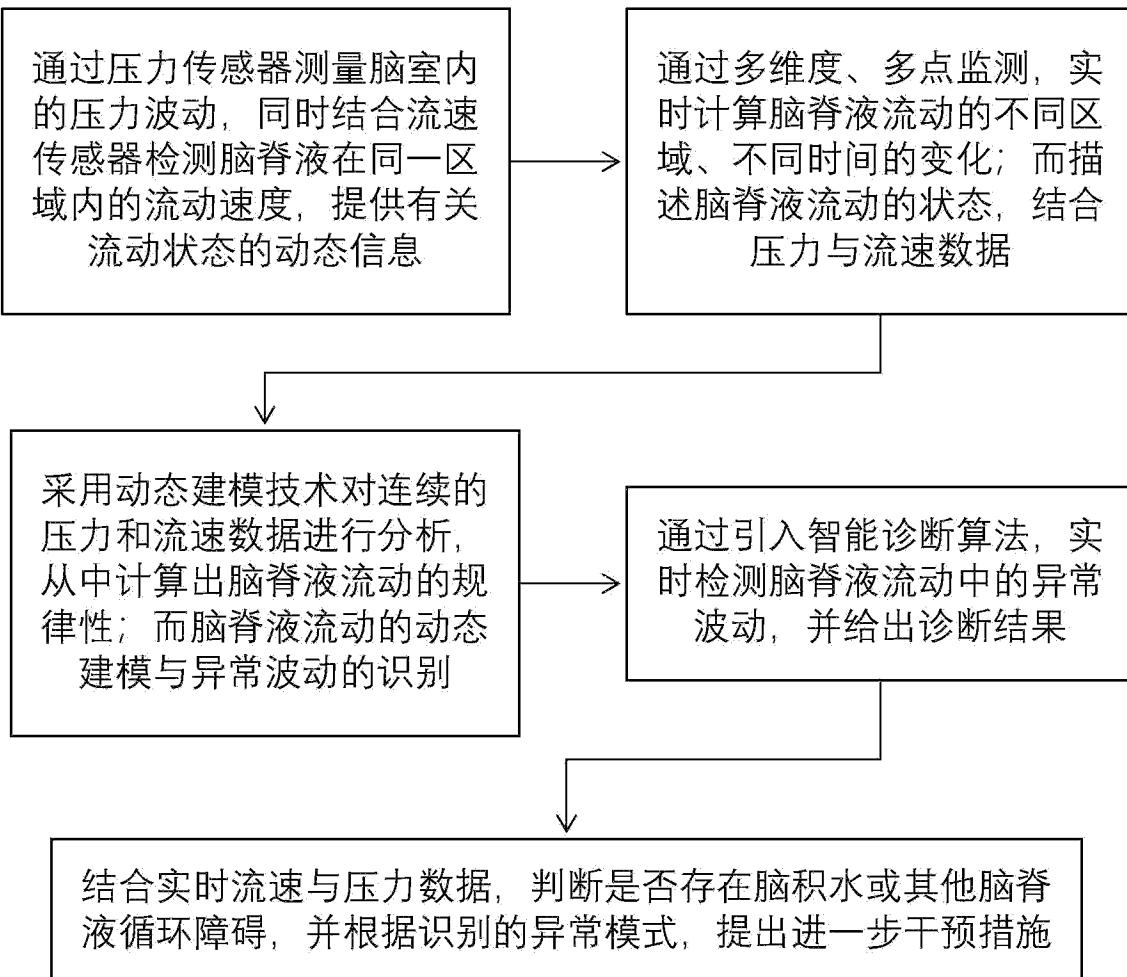


图2

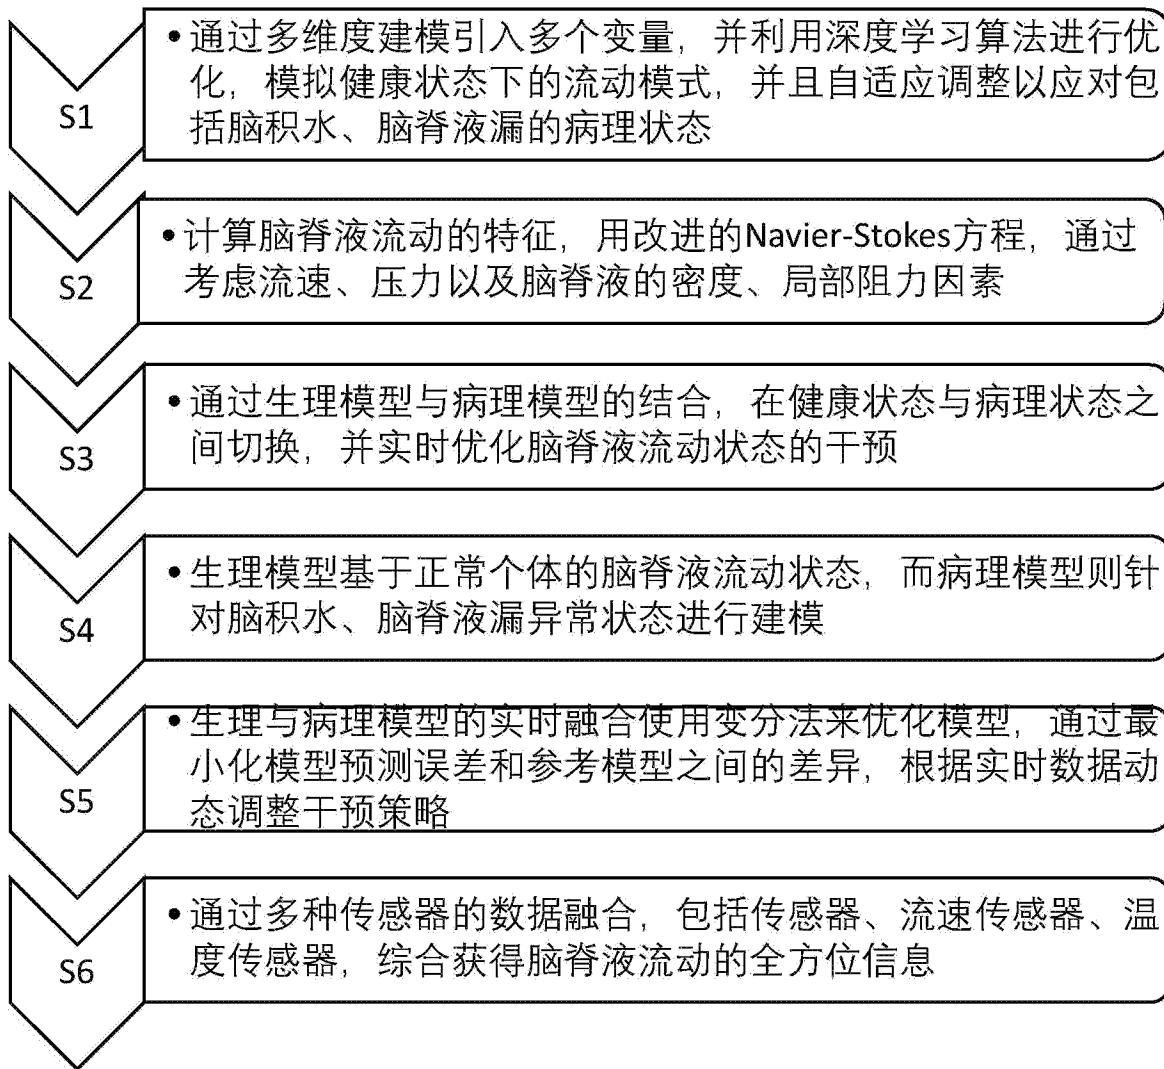


图3