

S 表示在图像上进行扫描时的移动步长。对于一般应用场景下，各卷积层中可用以进行迭代的物理参数总量 N_{para} 的计算方法为：

$$N_{para} = (N_{imap} \times R + 1) \times N_{omap} \quad (2.10)$$

其中， N_{imap} 表示卷积层中所输入特征图的数量； N_{omap} 表示卷积层中所输出特征图的数量。

为直观展示卷积层的工作原理，以某 3×3 卷积核对某 6×6 输入信息的处理过程为例进行解释，如图 2.2 所示。其中，蓝色、红色的虚线框分别对应于卷积核 1、2 的运算操作过程；参数设置方面，卷积核以数值为 1 的指定步幅在输入信号上进行滑动，并通过逐点相乘后得到对应的输出信号。整个卷积层经运算后可分布得到 4×4 的向量。

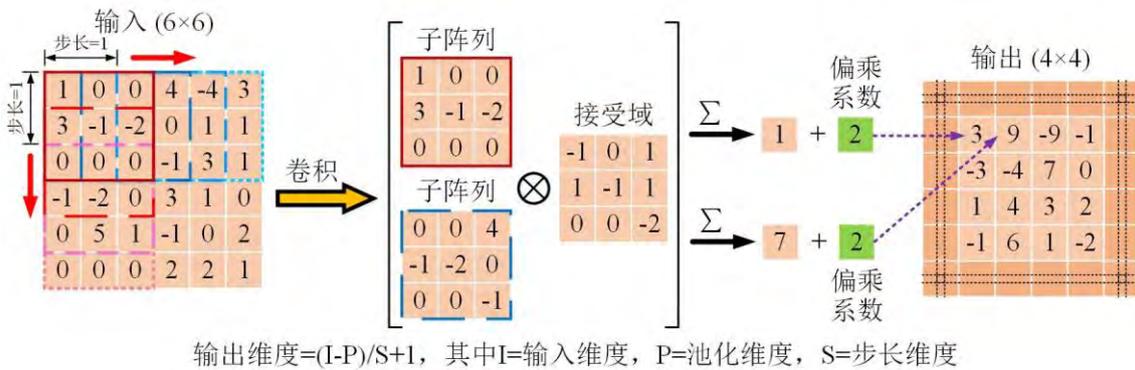


图 2.2 卷积层操作示意图

卷积层的输出结果在经过非线性函数变换处理后，可实现对所提取对象特征的筛选辨识，以达到对模拟神经元的激活阈值控制。通常情况下，DCNN 网络中多采用 Sigmoid、Tanh 及 Softsign 等传统饱和非线性函数(Saturating nonlinearities)进行计算。近年来，以 ReLU 等为代表的饱和和非线性函数(Non-saturating nonlinearities)被逐渐应用至 DCNN 网络的操作运算过程当中。该类函数在保持较高计算效率的基础上，能够有效避免因特征传递梯度过大/过小所可能导致的梯度爆炸/消失现象^[87]。常用的激励函数函数示例汇总如图 2.3 所示。

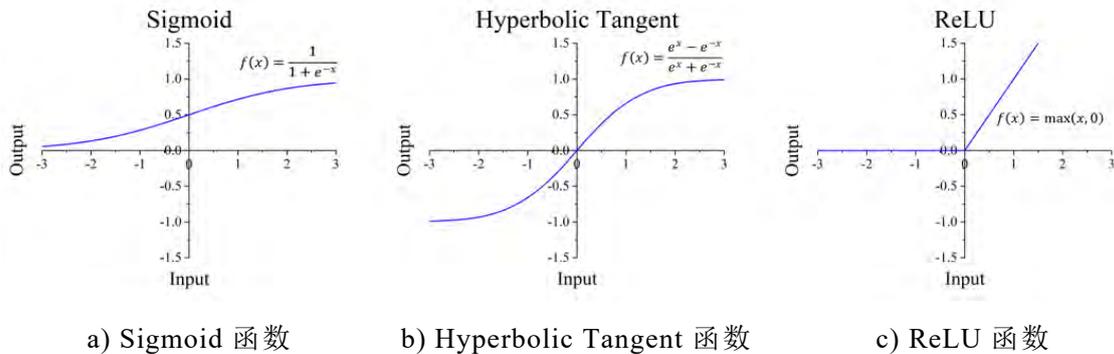


图 2.3 DCNN 网络常用激活函数

(2) 池化层 (Pooling layer, POOL layer)。池化层又被称为下采样层

(Sub-sampling layer), 其通常被设置在卷积层后面。该网络层通过对特征图进行压缩, 在完成减小特征图尺寸、降低模型计算复杂度等工作的基础上, 可有效实现对样本特征信息的压缩, 从而完成对物体主要特征的提取^[88]。与卷积层类似, 池化层同样由多个特征面组成, 且其中各特征面均与上一层的特征面对应, 从而保证特征面的总数量保持恒定。物体信息经池化操作后, 可减少模型在训练过程中所需参数的总量, 且能够较好地对图像中的空域特征信息进行学习; 同时, 在保证对扰动、缩放和其他形式扭曲不变性的基础上, 可有效地避免过拟合现象的发生。然而, 与卷积层略有不同, 池化层中所需进行设置的相关参数主要为卷积核大小和滑动步长。依据所输入信号尺寸及预设卷积核的大小, 特征数据在经池化操作后可实现调整数据规模、提高计算效率及突出局部统计特征等功能^[88]。

通常情况下, 池化操作可分为平均池化、最大池化、最小池化和随机池化等形式。其中, 平均池化(Average pooling)操作侧重于保存图像中的背景特征等信息, 其通过所设置的扫描窗口对相应特征区域内的像素均值 P_A 进行计算, 从而实现对所池化区域内特征信息的数学平均; 最大池化(Max pooling)则侧重于保留图像的纹理等信息, 其将所计算区域内的像素均值 P_A 替换为最大值 P_M , 并输出传递至下一网络层; 最小池化(Minimum pooling)及随机池化(Stochastic pooling)等操作一般使用较少, 在此不做赘述。值得注意的是, 在池化操作阶段, 尽管所输出特征图的分辨率在一定程度上有所下降, 但其仍能较好地保留后续计算过程中所需的相关特征信息。池化阶段所涉及的相关计算公式具体如下^[86]:

$$x_j^l = \beta_j^l \otimes x_j^{l-1} + b_j^l \quad (2.11)$$

其中, β_j^l 表示第 l 个网络层中的第 j 个偏置; \otimes 表示池化操作所涉及到的相关计算方式; b_j^l 表示第 l 个网络层中的第 j 个偏置。

对于网络模型中的池化层而言, 所输出特征图的规格尺寸 $O_x \times O_y$ 可表示为:

$$O_x = \frac{I_x - f_x}{S} + 1, \quad O_y = \frac{I_y - f_y}{S} + 1 \quad (2.12)$$

其中, $I_x \times I_y$ 表示池化层中输入特征图的规格大小; $f_x \times f_y$ 表示对应卷积核的尺寸大小; S 表示池化操作在进行扫描时所需的移动步长。

为直观展示池化层工作原理, 以对某 7×7 维度特征图的处理过程为例进行解释, 如图 2.4 所示。其中, 虚线框在经最大或平均池化计算后, 其所在区域内的最大值将被对应提取出来。参数设置方面, 定义池化筛选器以大小为 2 的步幅增量在全局特征面上进行滑动, 并最终固定维度的信号形式进行输出。

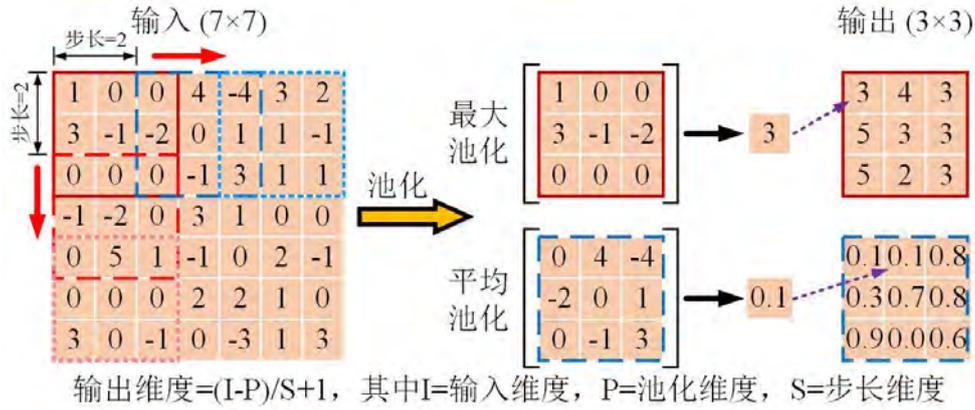


图 2.4 池化层操作示意图

(3)全连接层(Fully connected layer, FC layer)。全连接层通常设置在池化层后面，其所需训练的模型参数相对较多。该网络层中的各结点均与前一网络层中的所有结点进行相连，用以实现对先前阶段所提取特征信息的归纳整合，并将其传递输入至所相应设置的分类器中。即全连接层在整个 DCNN 网络模型中额外起到了特征分类的作用^[89]。其通常所涉及到的分类器大多以端对端(End to end)的形式完全嵌入至 DCNN 网络模型的底部。这种设计方式不仅能在降低计算运行量的基础上实现较高的测试精度，同时还具有较强的分布处理能力，可充分表达复杂的模型非线性关系。一般而言，分类器大多采用交叉熵损失(Cross-entropy loss)作为损失函数，具体表示如下^[89]：

$$L_i = -f_{y_i} + \log \sum_j e^{f_{y_j}} \quad (2.13)$$

其中， L_i 表示第*i*个标签中的特征损伤程度； j 表示所设置标签的总数量； f_y 表示特征信息经前向传播后所生成的特征向量。

(4)输出层(Output layer)。作为 DCNN 网络的最后一层，输出层通常设置在全连接层之后。针对不同的使用用途，输出层中所产生的信息也有所不同。对于物体检测问题，输出层所导出的信息多为测试对象的几何尺寸及坐标信息；对于语义分割问题，输出层通常为对各像素的直接分类结果；对于图像辨识问题，为实现对所输入数据的分类辨识，DCNN 网络的输出层通常设置为采用逻辑回归的分类器(如 Softmax 等)，其相应的输出层则一般使用逻辑函数进行结果分类^[90]。

对于 Softmax 分类器而言，通常是由处理二分类问题的逻辑回归模型扩展而来的。针对多目标分类问题，假设其训练集中预先设置有*k*类对象，并将图像及对应所属标签类型分别定义为 $x^{(i)}$ 、 $y^{(i)}$ ，则*m*个带有标签的样本可被定义为 $\{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})\}$ ，同时相对应的概率值可表示如下^[86]：

$$h_W(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | y^{(i)}; W) \\ p(y^{(i)} = 2 | y^{(i)}; W) \\ \vdots \\ p(y^{(i)} = k | y^{(i)}; W) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{w_j^T x^{(i)}}} \begin{bmatrix} e^{w_1^T x^{(i)}} \\ e^{w_2^T x^{(i)}} \\ \vdots \\ e^{w_k^T x^{(i)}} \end{bmatrix} \quad (2.14)$$

其中, $p(y = j|x)$ 表示样本 x 经估计运算后被分类至类别 j 中的概率值; W_1, W_2, \dots, W_k 表示神经网络在计算过程中所需设置的相关参数; $1/(\sum_{j=1}^k e^{W_j^T x^{(i)}})$ 表示对计算概率分布结果进行归一化处理时的权值系数。

通常情况下, 神经网络中分类器经计算后所输出的概率结果可能会与实际结果之间产生一定误差。若将该误差结果定义为损失函数, 则相应的函数表达式可总结为:

$$J = -\frac{1}{m} [\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)} = j\} \log \left(\frac{e^{W_j^T x^{(i)}}}{\sum_{l=1}^k e^{W_l^T x^{(i)}}} \right)] \quad (2.15)$$

其中, $1\{\dots\}$ 表示指示函数, 即当该表达式表示真值时, 相应的函数取值结果为 1, 否则便取值为 0。另一方面, 某样本 x 在经计算后被分类至类别 j 的概率结果可总结为:

$$p(y^{(i)} = 1|x^{(i)}; W) = \frac{e^{W_j^T x^{(i)}}}{\sum_{l=1}^k e^{W_l^T x^{(i)}}} \quad (2.16)$$

2.4 经典卷积神经网络模型

近年来, DCNN 网络中所用于进行图像分类任务的经典算法主要包括 LeNet、AlexNet、ZFNet、VGGNet、GoogLeNet 和 ResNet 等^[91]。其中, LeNet 于 1994 年首先提出, 最初是针对手写字符识别任务所设计而成的。该算法的出现奠定了 DCNN 网络的基本架构组成, 后续相关算法均是在此基础上拓展所得的。2012 年, AlexNet 通过在该年度的视觉识别挑战赛 (Imagenet large visual recognition challenge, ILSVRC) 中勇夺桂冠而迅速被科研工作者所得知, 其卓越的图像分类能力也使得基于 DCNN 网络的深度学习理论开始逐渐出现在大众视野。作为 2013 年的 ILSVRC 挑战赛冠军, ZFNet 通过对 AlexNet 模型的部分参数进行调整, 使得网络模型的性能得到了较大幅度的提升。2014 年, VGGNet 通过采取增加神经网络层数的方式, 使得模型的泛化能力得以增强, 且该模型经迁移训练后对于其他数据图像的识别效果也较为理想。其中, VGGNet 模型主要包括 VGG-16 和 VGG-19 两个版本。同年, 相关科研团队所提出的 GoogLeNet 模型通过采取增强网络层个数、引入 Inception 模块等方式, 成功获得了该年度的 ILSVRC 图像分类竞赛冠军。2015 年, 微软公司设计了包含 152 个中间网络层在内的 ResNet 模型, 其通过在对神经网络模型架构组成进行调整的基础上, 创新性地提出了利用残差模块解决模型测试精度随网络层数增加而逐渐损失的方法; 现有的 ResNet 神经网络主要用于对灰度图像进行分析处理。总体而言, 以 GoogLeNet 及 ResNet 等为代表的大型深层 DCNN 网络模型的性能相对较好, 但其庞大的神经元数量及复杂的模型结构也导致其在训练过程中所需消耗的内存及时间成本过大, 且对计算机的性能配置情况具有很高的要求。通常情况下, 以 AlexNet 和 VGGNet 为代表的

卷积神经网络模型在相关科学研究问题中使用的相对较多。

2.4.1 AlexNet 模型

作为近年来深度学习领域中所产生的一种经典算法，AlexNet 模型现已被国内外相关学者广泛应用于图像分类领域内的深度学习识别任务。模型架构方面，整个深层 AlexNet 模型共由 11 个不同层次的网络层组成，其分别包含有 5 个卷积层、3 个池化层以及 3 个全连接层^[81]，如图 2.5 所示。其中，输入层需导入规格尺寸为 227×227 像素的 RGB 三通道图像。对于中间网络层而言，中间层 1 分别包含有卷积层和池化层等两个网络层，其中卷积层由 96 个 $11 \times 11 \times 3$ 的卷积核组成，池化层则由 3×3 的池化核组成，且采用最大池化方式进行处理；对于中间层 2 而言，分别由 256 个 $5 \times 5 \times 96$ 的卷积核及 3×3 的池化核组成，并以中间网络层 1 的输出结果作为特征信息输入；中间层 3 和中间层 4 则分别由 384 个 $3 \times 3 \times 256$ 及 $3 \times 3 \times 384$ 的卷积核组成；中间层 5 同样由卷积层和池化层等两个网络层组成，均包含了 256 个 $3 \times 3 \times 384$ 和 3×3 的神经核。除此之外，第 6、7 网络层为组成架构完全相同的全连接层，且神经元个数均为 4096；第 8 网络层中的神经元个数则为 1000，并且额外设置有 Softmax 分类器进行结果输出。值得注意的是，为提高对训练数据集的运行计算效率，在 AlexNet 模型中采用了 ReLU 激活函数来对网络训练过程进行加速；并通过引入 Dropout 技术在一定程度上减小过拟合现象发生的概率^[92]。

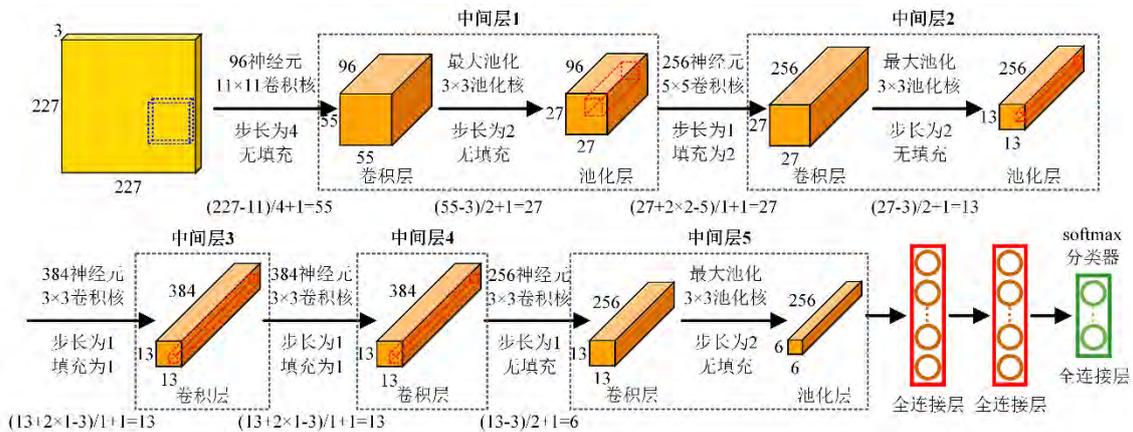


图 2.5 AlexNet 卷积神经网络模型

2.4.2 VGG-16 模型

与 AlexNet 神经网络相比，VGG-16 卷积神经网络模型的结构相对较为复杂，共包括有 16 个中间卷积层，如图 2.6 所示。其中卷积核大小为 3×3 ，且滑动步长设置为 1；池化层中所使用的池化核大小为 2×2 ，滑动步长则定义为 2。网络架构设置方面，VGG-16 卷积神经网络模型由 5 个卷积层、3 个全连接层和 1 个 Softmax 层组成^[93]。其中，每个卷积层均由设置有 ReLU 的卷积层及采用最大池化方式的池化

层组成。具体而言，首个卷积层中的卷积核数量为64，网络规模设置为2层；第二个卷积层中卷积核数量为128个，网络规模设置为2层；第三个卷积层中卷积核数量为256，网络规模设置为3层；第四、五个卷积层中卷积核数量均为512，网络规模设置为3层。在模型的三个全连接层中，其神经元数量分别设置为4096、4096及1000；同时，通过定义ReLU激活函数对计算结果进行收敛。除此之外，在前两个全连接层中，还引入了Dropout函数对模型过拟合现象进行改善；对于最后一个全连接层，则将其输出结果将直接传递至Softmax层中进行处理。

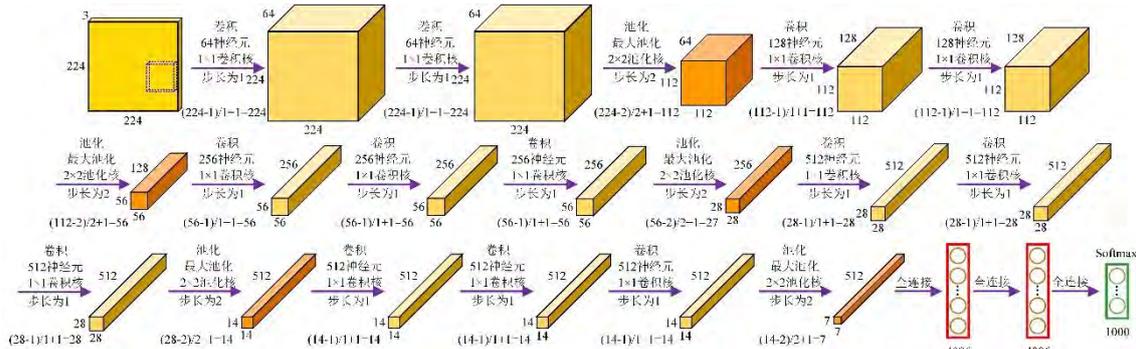


图 2.6 VGG-16 卷积神经网络模型

2.5 卷积神经网络训练原理

DCNN 网络的工作过程可分为网络定义、网络训练和网络预测三部分^[94]。其中，网络定义部分需要依据所训练数据样本的类型、特征及容量等信息，设置相应的网络尺度及参数取值；网络训练阶段则是将经预处理后的数据输入至网络模型中，并通过残差反向传播过程对网络中各参数进行训练；网络预测阶段则是基于前向传播过程，利用输入数据在各网络层上得到相应特征图后，再通过全连接层输出测试数据的条件概率分布情况。在实际训练过程中，网络模型通常可能会产生梯度弥散或过拟合现象。若当训练效果不理想时，则需要依据计算结果对相关参数进行调整，直至网络性能表现良好。与传统机器学习方式有所不同，当将原始图像直接作为信息输入时，DCNN 网络可避免对图像中复杂特征进行重建这一繁琐步骤，从而有效提高了计算效率。值得注意的是，DCNN 网络可通过局部感受野进行特征信息提取，且不受图像的平移、缩放及旋转等操作影响。其相应的神经网络训练原理主要涉及特征信息传递、随机梯度下降及泛化能力评估等三个方面。

2.5.1 特征信息传递

DCNN 网络的训练过程包括前向传播和反向传播两个阶段。其中前向传播是指各网络层对物体特征信息进行系统性学习的过程；反向传播则是指网络训练过程中通过参数调节等措施，从而不断缩小模拟输出与真实输出间误差的过程^[95]。

(1)前向传播阶段。在该阶段，所训练样本从输入层开始向前逐层进行卷积、池化操作，并对每一层的参数值进行更新计算，直至得到最终的输出结果。对于DCNN网络，由于其输入和输出结果的表现形式均为特征图，故在输入特征图上进行卷积操作后，再将所得结果传递至对应的激活函数中，即可得到相应的计算输出结果。这一过程的计算原理可表示为^[86]：

$$x_j^l = f(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l) \quad (2.17)$$

其中， x_j^l 表示第 l 个网络层中所对应的第 j 个特征图； $f(\dots)$ 表示相应设置的激活函数； M_j 表示所输入特征图的信息数组； $*$ 表示卷积操作所涉及到的相关计算方式； k_{ij}^l 表示第 l 个网络层中所对应特征图 j 与第 $l-1$ 个网络层中所对应特征图 i 之间的卷积核； b_j^l 表示特征图 x_j^l 所对应的偏置系数。

通常情况下，需要对网络模型中所输入的特征图做一系列的局部采样处理。相关计算过程可表示如下：

$$x_j^l = f(\beta_j^l \text{down}(x_i^{l-1}) + b_j^l) \quad (2.18)$$

其中， β_j^l 表示特征图 x_j^l 所对应的计算系数； $\text{down}(\dots)$ 表示下采样函数。

(2)反向传播阶段。由于前向传播阶段中的输出结果与实际情况之间通常会存在一定误差(定义为误差函数 J)，故反向传播阶段相关操作的实质是基于误差计算结果，由输出层至输入层的方向反向地计算各网络层中参数的偏导数，并对相应的参数进行更新。

当某卷积层 l 与某池化层 $l+1$ 相连时，可基于反向传播概念对由第 l 层神经元中残差 δ 所导致的梯度信息进行计算。在对池化层进行扩充后，通过计算样本扩充后残差图与对应特征图偏导数之间的乘积，即可求得第 l 个网络层中神经元残差 δ 的信息情况。若假设池化层中特征图的相关参数取值为 β ，则相关的计算公式可表示为^[86]：

$$\delta_j^l = \beta_j^{l+1} (f'(u_j^l) \times \text{up}(\delta_j^{l+1})) \quad (2.19)$$

其中， \times 表示对特征图中各像素点进行乘积运算； $\text{up}(\dots)$ 表示上采样函数。

DCNN网络基于残差图的计算结果，能够相应求解卷积层中的相关偏置参数及与卷积核梯度信息有关的训练参数。该过程可具体表示为：

$$\frac{\partial J}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{uv}, \quad \frac{\partial J}{\partial k_{ij}^l} = \sum_{u,v} (\delta_j^l)_{uv} (p_j^{l-1})_{uv} \quad (2.20)$$

其中， u, v 表示网络中特征图上所对应的各像素点信息； $(p_j^{l-1})_{uv}$ 表示在卷积计算阶段与第 k_{ij}^l 个网络层进行相乘的特征区域。

另一方面，在对残差图进行计算的过程中，需要在明确当前所需计算残差图中局部区域与后一网络层中残差图区域之间相互关联程度的基础上，通过将其与输入/输出图像之间的权重参数进行乘积运算，以此获得最终结果。这一过程具体可表示如下：

$$\delta_j^l = f^{(u_j^l)} * \text{conv2}(\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), 'full') \quad (2.21)$$

对于运算过程中所涉及到的偏置参数 b 和特征图参数 β ，相应的计算理论可具体表示如下：

$$\frac{\partial J}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{uv}, \quad \frac{\partial J}{\partial \beta_j} = \sum_{u,v} (\delta_j^l * d_j^l)_{uv} \quad (2.22)$$

其中， $d_j^l = \text{down}(x_j^{l+1})$ 。

2.5.2 随机梯度下降

DCNN 网络的训练过程本质上是通过反复迭代方式，不断降低训练过程中所产生的损失函数值，从而使得预测结果逐渐逼近真实情况。同时，为提高计算效率，可通过使用一系列优化算法来搜寻可使得损失函数值最小化的模型参数。对于 DCNN 网络，该类型优化算法通常被定义为随机梯度下降算法(Stochastic gradient descent momentum, SGDM)，且被认为是一种最小化损失函数值的有效方法^[96]。

对于随机梯度下降算法，其通过在所有数据集中随机挑选一组样本进行迭代训练，并将该组样本的容量定义为最小批次数量，从而避免了每次迭代过程中因参数更新而需对整个训练数据集进行反复训练的繁琐过程。除此之外，为提高模型训练效率，随机梯度下降算法中还额外引入了动量(Momentum)的概念，即通过优化相关方向训练、弱化无关方向训练等方式加快训练速率；其动量数值通常设置为 0.9。所涉及的更新流程可主要分为三个阶段。首先，需对损失函数的梯度信息结果进行计算。该过程可具体表示为^[86]：

$$\nabla_W J(W; x^{(i)}, y^{(i)}) = \frac{1}{m} \sum_{i=1}^m [x^{(i)} \{1(y^{(i)} = j) - p(y^{(i)} = j | x^{(i)}; W)\}] + \lambda W_j \quad (2.23)$$

其中， m 表示网络层中的样本总量； $x^{(i)}$ 表示数据集中的第 i 个样本； $y^{(i)}$ 表示针对数据集所对应设置的标签类型； W 表示神经网络中所设置的相关训练参数结果； $p(y^{(i)} = j | x^{(i)}; W)$ 表示分类器中所输出样本 $x^{(i)}$ 被分类至标签类别 j 的概率。

其次，通过设置动量参数 ε 及学习率系数 α 等信息，可实现对训练下降速率指标 v 的更新工作，从而满足：

$$\varepsilon v - \alpha \nabla_W J(W; x^{(i)}, y^{(i)}) \rightarrow v \quad (2.24)$$

最后，通过对参数值 W 进行迭代更新，从而使得：

$$W_j + v W_j \rightarrow W_j \quad (2.25)$$

DCNN 网络在经多次迭代后，可得上式(2.25)逐渐进行收敛。根据相关计算经验可知，当学习率参数设置较大时，网络收敛速率将相应加快，但模型可能将收敛至局部最优点，甚至增大损失函数值，即发生溢出现象；当学习率设置较小时，则网络计算收敛速率将随之降低，从而导致模型训练效率不高。

2.5.3 泛化性能评估

对于现有的机器学习技术而言，其实施关键所在是利用经训练后的神经网络模型对数据集合进行拟合分析。相应地，评估一个神经网络模型经训练后的性能水平，关键在于其是否能对测试集合中的各样本做出正确识别。这里，将神经网络模型在测试数据集上试验所得的误差定义为泛化误差，并将模型对除训练集之外的各样本预测情况定义为模型的泛化能力。通常情况下，多利用混淆矩阵(Confusion matrix)对经训练后神经网络模型在测试数据集上的泛化性能进行评估。

具体而言，混淆矩阵是深度学习任务中一种用于评估神经网络模型分类预测结果的判断指标，通常以矩阵形式将测试样本按照真实类别和预测类别进行汇总^[86]。对于一个多分类问题而言，其中类别*i*的预测准确率被定义为模型预测正确的样本数量与所输入该类型样本总数量之比，具体可表示为^[86]：

$$p_i = \frac{Q_{ii}}{\sum_{j=1}^n Q_{ij}} \tag{2.26}$$

其中， Q_{ij} 表示混淆矩阵中第*i*行第*j*列中所对应的数据。

对于经训练后神经网络模型，其在测试数据集上的准确率则被定义为预测正确的样本数量与所输入样本总数量之比，具体表示为：

$$Accuracy = \frac{\sum_{i=1}^n Q_{ii}}{\sum_{i=1}^n \sum_{j=1}^n Q_{ij}} \tag{2.27}$$

以某一 3×3 阶混淆矩阵为例进行介绍(如图 2.7 所示)，其中每行中的各项数据代表该样本的真实归属类别，且其数据量之和便代表该类别的真实样本总量；每列中的各项数据则表示该样本经训练后被预测的所属类别，且其数据量之和便代表被预测为该类别的样本总量。同时，对角线上各数值结果即表示该神经网络预测正确的部分，非对角线上的结果则表示预测有误的部分。因此，当对角线上的数值越高时，表示神经网络模型的训练效果越准确。

分类输出	类别1	43 (15.4%)	2 (0.0%)	0 (0.0%)	95.6% (4.4%)
	类别2	5 (1.5%)	45 (66.2%)	1 (0.7%)	88.2% (11.8%)
	类别3	2 (0.0%)	3 (0.0%)	49 (16.2%)	90.7% (9.3%)
	测试精度	86.0% (14.0%)	90.0% (10.0%)	98.0% (2.0%)	92.7% (7.3%)
		类别1	类别2	类别3	测试精度
		预测结果			

图 2.7 混淆矩阵示意图

2.5.4 训练优化方式

深度学习模型训练方面,由于大型深层 DCNN 网络模型的训练参数量通常十分巨大(如 AlexNet 模型的参数量共计约为 6000 万),若对其进行直接训练则可能导致在计算效率、参数调整及模型性能方面产生诸多问题^[97]。因此,为尽可能地获取较为理想的 DCNN 网络模型,可采用迁移学习(Transfer learning)方式进行相关科学问题的研究分析^[97]。其中,迁移学习是指将经大型数据集(如 ImageNet,约 1400 万张图片)训练过的神经网络模型进行参数调整后,用以实现对特定问题的识别处理。需进行说明的是,由于 DCNN 网络中前置低阶网络层所能提取到的信息大多为数据图像集中的浅层特征(如边缘、线条等),该类型特征对于绝大多数的图像识别任务具有一定通识性;而末端高阶网络层所提取到的信息才为测试对象所固有的特征本质,其通常将因数据集类型的不同而随之变化。因此,迁移学习的实质是保留经深度训练后 DCNN 网络模型的部分参数,并通过重置其他参数来进行模型训练^[97],如图 2.8 所示。目前,该方法已被大量学者应用至相关领域内的分类识别问题研究当中^[98]。

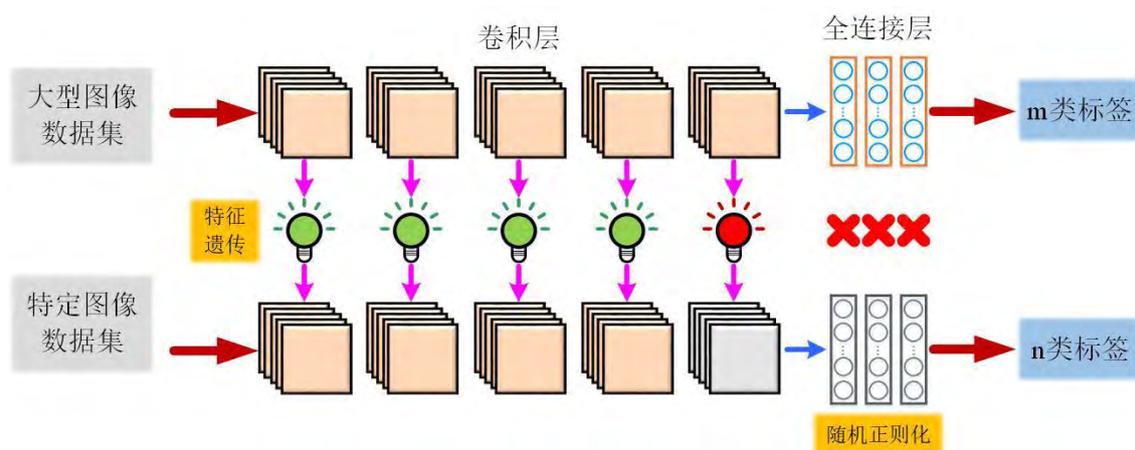


图 2.8 迁移学习示意图

对于经训练过的 DCNN 模型而言,通常情况下欠拟合(Under-fitting)现象和过拟合(Over-fitting)现象是造成神经网络泛化能力有待提高的两种常见原因,如图 2.9 所示。其中,欠拟合现象一般发生在模型学习能力相对较弱、而数据结构复杂度却相对较高等情况,此时由于神经网络在该阶段的自主学习能力相对较为有限,因而无法捕获到数据集合中所潜在的真实客观规律^[86];过拟合问题则是指因参数设置不当,导致 DCNN 网络模型在训练阶段对某些信息进行过度迭代拟合,从而最终影响到该模型在测试集上相应泛化能力的现象。其特征表现为网络模型在预设训练集上能够获得很好的识别效果,但在测试数据上的性能精度却较为有限^[86]。一般情况下,导致过拟合现象发生的原因主要有训练数据集过少、训练集存在数据错误、样本中干扰信息过多等因素;同时,当网络复杂度太高、权值迭

代次数过多、训练时间过长时，也容易使得模型拟合训练数据中的噪声和特征性不强等信息。

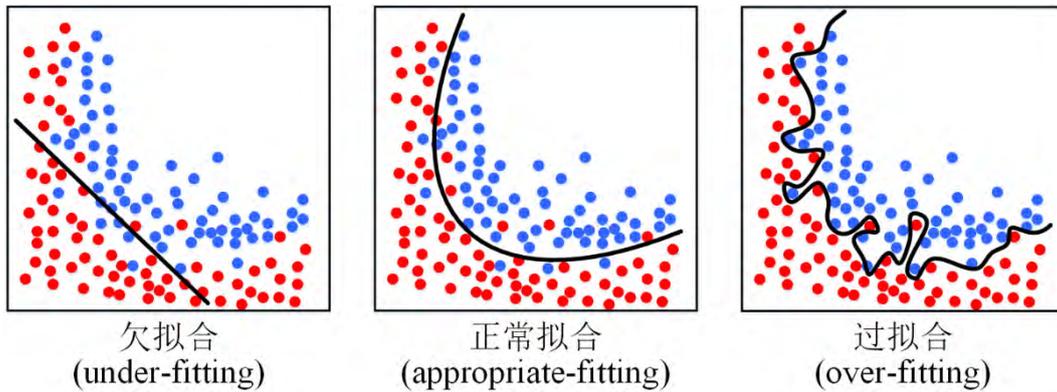


图 2.9 统计模型拟合现象分类

为减缓欠拟合现象，可通过丰富样本特征信息、适当增强模型复杂度等方式进行处理^[86]。对于减缓过拟合现象而言，则通常可采用正则化分析、Early stopping、Dropout 及数据增强等方式进行处理^[99,100]。其中，正则化分析是指在保证模型简单性原则的基础上，通过额外引入附加信息来解决过拟合问题；Early stopping 处理是指网络模型在训练过程中，在经反复迭代直至即将达到收敛状态时，通过终止迭代操作来防止过拟合现象发生；Dropout 操作是指在训练过程中通过将隐含层的部分权重或输出随机归零，降低节点间的相互依赖性，从而减缓过拟合现象发生的概率；数据增强则是通过对数据集进行特定处理，以此提高样本数量的方式。通常情况下，训练集样本容量越多，所可能发生过的拟合的概率将随之降低。常用的数据增强手段主要有翻转变换、缩放变换、裁剪变换、平移变换、颜色变换及噪声扰动等。

2.6 车-桥振动简化模拟测试

关于车载荷载信息识别的反问题研究方面，考虑到时-频分析技术能够对结构响应中潜在的特征信息进行有效提取，且深度学习方法具备强大的特征信息自主学习能力，故拟将其应用至对车-桥振动信号的分析解读当中。具体而言，首先利用时-频分析技术对结构动力响应中的特征信息进行提取，并通过深度学习网络对挖掘不同激励源作用下特征响应中所隐含的分布规律及模式进行挖掘，从而完成对外部车载信息的判断识别，并最终实现一种利用深度学习网络代替结构系统建模、仅利用输出响应便可获取输入信息的反问题求解技术。

2.6.1 简化模型经典解析理论

(1) 匀速移动集中荷载模型。该模型不需要考虑车辆在行驶过程中所产生的质量效应，通常适用于车辆质量与桥梁质量相比相对较小的情况^[101]，如图 2.10 所

示。

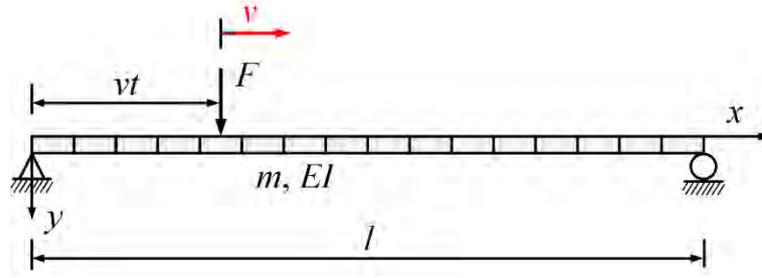


图 2.10 匀速移动集中力模型

结构响应解析结果求解方面，以简支梁最左端为原点建立平面坐标系。假设在初始 $t=0$ 时刻，存在某一恒定集中力 F 作用于坐标系 $x=0$ 位置处；对于任意时刻 t ，集中力 F 将匀速移动至距原点距离 $x=vt$ 位置处。因此，在外部集中荷载 F 作用下简支梁模型的动力学微分方程可表示为^[101]：

$$EI \frac{\partial^4 y}{\partial x^4} + m\ddot{y} = F \quad (2.28)$$

其中， EI 表示简支梁的抗弯刚度； m 表示简支梁单位长度所对应的质量。

若将简支梁模型在外荷载强迫振动下所产生的动位移响应以振型级数形式进行表示，则有：

$$y(x, t) = \sum_{n=1}^N \varphi_n(x) q_n(t) \quad (2.29)$$

对上式进行解耦运算，可得该系统的强迫振动方程为：

$$\ddot{q}_n(t) + \omega_n^2 q_n(t) = Q_n(t) \quad (n = 1, 2, 3, \dots, N) \quad (2.30)$$

其中：

$$\omega_n^2 = \frac{EI \int_0^l \left[\frac{d^2 \varphi_n(x)}{dx^2} \right]^2 dx}{m \int_0^l \varphi_n^2(x) dx}, \quad Q_n(t) = \frac{\int_0^l p(x, t) \varphi_n(x) dx}{m \int_0^l \varphi_n^2(x) dx} \quad (2.31)$$

对于简支梁模型，其振型表达式为 $\varphi_n(x) = \sin(n\pi x/l)$ 。因此，对于以恒定速率移动的集中力 F ，其所产生的广义激励力可表示为：

$$Q_n(t) = \frac{\int_0^l F \delta(x-vt) \varphi_n(x) dx}{m \int_0^l \varphi_n^2(x) dx} = \frac{\int_0^l F \delta(x-vt) \sin(n\pi x/l) dx}{m \int_0^l \sin^2(n\pi x/l) dx} = \frac{2F}{ml} \sin \frac{n\pi x}{l} \quad (n = 1, \dots, N) \quad (2.32)$$

因此，式(2.30)可表达为：

$$\ddot{q}_n(t) + \omega_n^2 q_n(t) = \frac{2F}{ml} \sin \frac{n\pi x}{l} \quad (2.33)$$

当集中力由静止状态开始运动时，求解上式可得到：

$$q_n(t) = \frac{2F}{ml\omega_n^2} \frac{1}{1 - \frac{\Omega_n^2}{\omega_n^2}} (\sin \Omega_n t - \frac{\Omega_n}{\omega_n} \sin \omega_n t) \quad (2.34)$$

其中， ω_n 表示简支梁模型的固有振动频率，其数值大小为 $\omega_n = (\frac{n\pi}{l})^2 \sqrt{EI/m}$ ； Ω_n 表示集中力作用下简支梁所产生的广义扰动频率，其数值大小为 $\Omega_n = n\pi v/l$ 。因此，简支梁模型的动力响应可表示为：

$$y(x, t) = \frac{2F}{ml} \sum_{n=1}^N \frac{1}{\omega_n^2 - \Omega_n^2} (\sin \Omega_n t - \frac{\Omega_n}{\omega_n} \sin \omega_n t) \sin \frac{n\pi x}{l} \quad (2.35)$$

(2) 匀速移动集中质量模型。当移动荷载的质量与桥梁结构整体相比不可忽略时，便需要对其因质量而产生的惯性力效应进行考虑^[101]。通常情况下，利用一匀速移动的集中质量块对该类情况进行模拟，如图 2.11 所示。

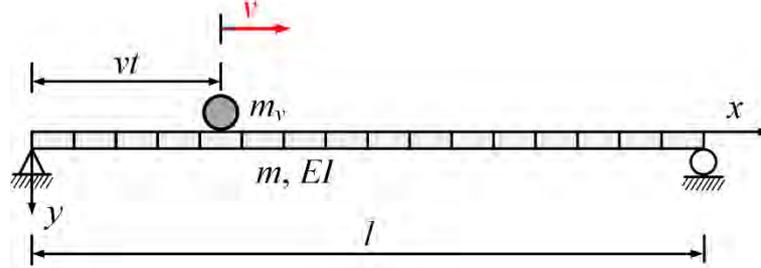


图 2.11 匀速移动集中质量模型

对于任意时刻 t ，假设集中质量在运动过程中与简支梁始终保持接触，则外部荷载对结构的作用力便等于其自重与荷载惯性力之间的差值，可将其表示为^[101]：

$$F(t) = m_v g - m_v \ddot{y}(x, t) \delta(x - vt) \quad (2.36)$$

其中， m_v 表示集中荷载的质量； g 表示重力加速度。

若令 $y(x, t) = \sum_{n=1}^N \varphi_n(x) q_n(t)$ ，则有 $\ddot{y}(x, t) = \sum_{n=1}^N \varphi_n(x) \ddot{q}_n(t)$ 。将其代入式 (2.36)，经整理后可得到：

$$F(t) = m_v g - m_v \sum_{n=1}^N \varphi_n(x) \ddot{q}_n(t) \quad (2.37)$$

对于简支梁模型，其振型表达式为 $\varphi_n(x) = \sin(n\pi v/l)$ 。因此，可将相应的广义扰动力表示为：

$$Q_n(t) = \frac{\int_0^l F_1(t) \delta(x-vt) \varphi_n(x) dx}{\int_0^l m \varphi_n^2(x) dx} = \frac{2m_v}{ml} [g - \sum_{n=1}^N \sin\left(\frac{i\pi vt}{l}\right) \ddot{q}_i(t)] \sin\left(\frac{n\pi vt}{l}\right) \quad (2.38)$$

因此，经振型分解处理后无阻尼结构的强迫振动方程可表示为：

$$\ddot{q}_n(t) + \omega_n^2 q_n(t) = \frac{2m_v}{ml} [g - \sum_{n=1}^N \sin\left(\frac{i\pi vt}{l}\right) \ddot{q}_i(t)] \sin\left(\frac{n\pi vt}{l}\right) \quad (2.39)$$

经移项整理后，可得：

$$\ddot{q}_n(t) + \left(\frac{2m_v}{ml} \sin\frac{n\pi vt}{l}\right) \sum_{n=1}^N \ddot{q}_i(t) \sin\left(\frac{i\pi vt}{l}\right) + \omega_n^2 q_n(t) = \frac{2m_v g}{ml} \sin\left(\frac{n\pi vt}{l}\right) \quad (2.40)$$

(3) 匀速移动弹簧-质量模型。对于现代化车辆而言，其一般均装有减震装置，不仅可降低移动车辆对桥梁的冲击效应，也改变了车辆系统本身的动力性能^[101]。通常情况下，分别利用集中质量及弹簧单元对车辆的质量及阻尼器进行模拟，如图 2.12 所示。

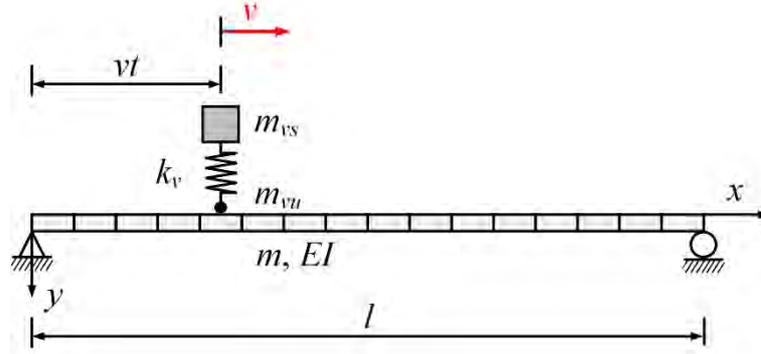


图 2.12 匀速移动弹簧-质量模型

由于在运动过程中车轮质量 m_{vu} 始终与桥梁表面保持接触，故其拥有独立的竖向振动自由度。因此，该弹簧-质量模型对简支梁的作用力可表示为^[101]：

$$F(t) = m_{vu}[g - \ddot{y}(x, t)\delta(x - vt)] + k_v[z - y(x, t)\delta(x - vt)] + m_{vs}g \quad (2.41)$$

其中， m_{vs} 表示车体的集中质量； z 表示以平衡位置为原点时质量 m_{vs} 所产生的绝对位移； k_v 表示车辆模型中悬挂系统的弹簧刚度。通常情况下，由于车辆轮载与车体质量相比相对较小，故式(2.41)中由 m_{vs} 项所造成的响应影响可忽略不计。

当令 $y(x, t) = \sum_{n=1}^N \varphi_n(x)q_n(t)$ 时，则有 $\ddot{y}(x, t) = \sum_{n=1}^N \varphi_n(x)\ddot{q}_n(t)$ 。由于简支梁的振型表达式为 $\varphi_n(x) = \sin(n\pi x/l)$ ，在将其代入至式(2.31)中后，便可得到：

$$F(t) = m_{vu}A_1 + k_vA_2 + m_{vs}g \quad (2.42)$$

其中，系数 $A_1 = g - \sum_{n=1}^N \ddot{q}_n(t) \sin\left(\frac{n\pi vt}{l}\right)$ ，系数 $A_2 = z(t) - \sum_{n=1}^N q_n(t) \sin\left(\frac{n\pi vt}{l}\right)$ 。

因此，在相应荷载作用下所产生的广义扰动力可表述为：

$$Q_n(t) = \frac{\int_0^l F(t)\delta(x-vt)\varphi_n(x)dx}{\int_0^l m\varphi_n^2(x)dx} = \left\{ \frac{2m_{vu}}{ml} A_3 + \frac{2k_v}{ml} A_4 + \frac{2m_{vs}g}{ml} \right\} \sin\left(\frac{n\pi vt}{l}\right) \quad (2.43)$$

其中，系数 $A_3 = g - \sum_{n=1}^N \ddot{q}_i(t) \sin\left(\frac{i\pi vt}{l}\right)$ ，系数 $A_4 = z(t) - \sum_{n=1}^N q_i(t) \sin\left(\frac{i\pi vt}{l}\right)$ 。

此时，经振型分解求解后无阻尼结构的强迫振动方程可表示为：

$$\begin{aligned} & \ddot{q}_n(t) + \left(\frac{2m_{vu}}{ml} \sin\frac{n\pi vt}{l} \right) \sum_{n=1}^N \ddot{q}_i(t) \sin\left(\frac{i\pi vt}{l}\right) + \omega_n^2 q_n(t) \\ & = \left\{ \frac{2(m_{vs}+m_{vu})g}{ml} + \frac{2k_v}{ml} [z(t) - \sum_{n=1}^N q_i(t) \sin\left(\frac{i\pi vt}{l}\right)] \sin\left(\frac{n\pi vt}{l}\right) \right\} \end{aligned} \quad (2.44)$$

通过对附加自由度建立动力平衡方程，即可利用数值方法对结构响应进行求解。该方式可表示为：

$$m_{vu}\ddot{z}(t) + k_v \left[z(t) - \sum_{n=1}^N q_n(t) \sin\left(\frac{n\pi vt}{l}\right) \right] = 0 \quad (2.45)$$

2.6.2 移动荷载-简支梁模型建立

针对车-桥计算这一类瞬态分析问题，在大型商用有限元软件 ANSYS 中相应提供有模态叠加法、缩减瞬态分析法及完全瞬态分析法等三种计算方法。其中，模态叠加法计算速度最快，但计算过程所需设置的时间步长必须保持恒定不变；缩减瞬态分析法计算速度相对较快，但不能施加单元荷载；完全瞬态分析法操作简单、计算效率高，适用于各种复杂的线性、非线性问题。在经过综合对比分析后，本章最终选用完全瞬态分析法进行移动荷载-简支梁模型的计算分析。

为验证所提出的基于深度学习理论及结构特征响应提取的桥梁上车辆荷载辨识方法的可行性，首先建立了较为常见的移动荷载-简支梁有限元模型，如图 2.13 所示。其中，设置移动荷载的幅值大小 $P=50\text{kN}$ 。简支梁模型采用 Beam 单元建立而成，桥梁跨度 $L=10\text{m}$ ，其横截面尺寸设置为 $H \times B=0.6\text{ m} \times 0.3\text{m}$ ；同时，简支梁的弹性模量 $E=210\text{GPa}$ ，密度 $\rho=7800\text{kg/m}^3$ ，并将其沿跨度方向的网格数划分为 100 个单元。在整个计算过程中，假设移动荷载由简支梁最左端原点处出发，并以恒定速度移动至模型最右端终点处。考虑到工程应用中部分传感器(如应变计、位移计等)在安装阶段的相关工作可能较为繁琐，且对于支座条件及稳定情况也存在一定敏感性，故在本方法中拟计划基于加速度信号进行相关研究。即通过提取简支梁结构模型跨中处的加速度响应，用以开展相关研究分析工作。

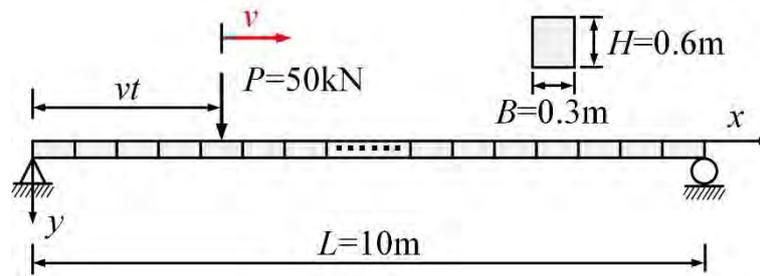


图 2.13 移动荷载-简支梁模型建立

2.6.3 移动荷载识别

2.6.3.1 车载识别

通过有限元数值模拟方式开展车载识别研究，对所提基于深度学习理论及结构特征响应提取的车辆荷载识别方法的可行性进行探究。试验过程中，保持荷载的行驶速度为 60km/h ，在保持功率恒定的情况下通过改变荷载幅值 M 的方式，来实现对不同车辆载重大小的模拟。其中，拟定设置了 $30\sim 50\text{kN}$ 、 $50\sim 70\text{kN}$ 及 $70\sim 90\text{kN}$ 三种测试工况。以模拟载重位于 $50\sim 70\text{kN}$ 范围内的情况为例，通过以 0.1 kN 的荷载增量，建立了样本量为 200 次测试工况的结构响应数据库。运营状态下的车辆荷载信息识别方面，针对桥梁结构在车辆荷载作用下所产生的动态信号，利用 DCNN 网络对其中蕴涵的特征响应信息及潜在的结构本质规律进行挖掘提

取，并经神经元反复训练迭代后实现对车辆荷载信息的分类识别。

值得注意的是，相关学者发现深度学习网络的训练效率与所输入对象的特征信息丰富程度密切相关。即当样本中所能提取到的特征信息较少时，神经网络模型可能将错误地对噪声等信息进行学习，从而导致欠拟合现象的发生；若样本间的特征信息较为明显时，则经训练后神经网络模型的性能将相对更好。因此，通过合适的数据分析方法对结构响应中的特征信息进行有效提取，在整个研究环节中具有重要意义。这里，为提高 DCNN 网络模型训练效率、避免欠拟合等现象的发生，通过利用 STFT、WVT 和 CWT 变换等三种时-频处理技术进行数据运算，并对比分析不同方法对经简支梁-移动荷载计算所得结构响应中特征信息提取的情况，如图 2.14 所示。可以发现，经 STFT 变换处理后的结构信号响应，其所提取到信息之间的特征差异性并不显著，即未能较好地对响应中所潜在的结构本质规律进行获取；WVT 变换下的数据处理效果虽相对有所提高，但其在运行计算过程中所消耗的时间成本代价过高，故不适于用来开展与大数据分析相关的科学问题研究。然而测试结果表明，基于 Morlet 基函数的 CWT 时-频分析技术可较好地实现对结构响应信号中相关特征信息的提取工作，且计算运行效率较高。因此，最终利用该方法对测试所得信息进行处理，并将提取到的特征信息转化为平面二维图像用以进行深度学习训练任务。

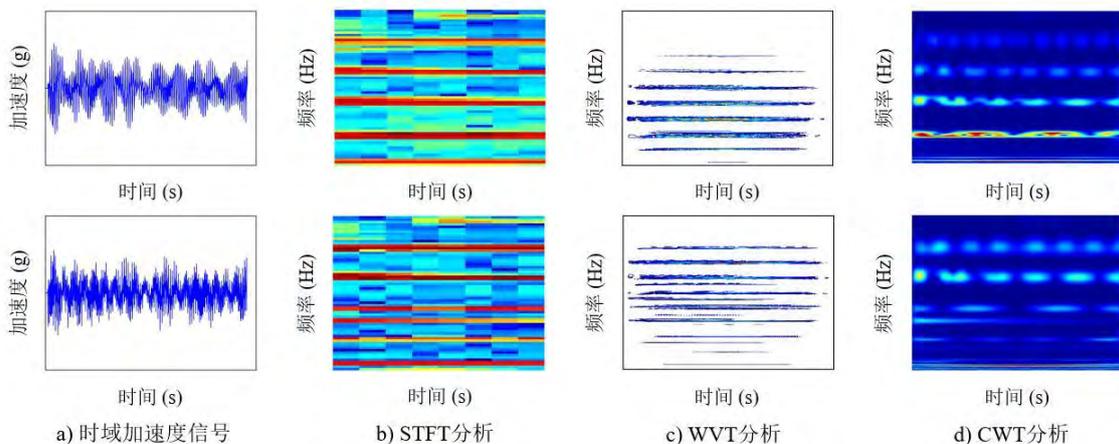


图 2.14 不同时-频分析技术提取特征响应信息对比

在建立结构特征响应的基础上，首先通过编写程序将数据库中的各样本分别转化为 227×227 像素的图片格式，以满足输入层对样本规格的特殊要求，如图 2.15 所示；其次，利用程序语言将各样本的命名形式统一设置为五位有效数字格式，并在内存文件中规定明确其所归属的测试工况类别；最终，将整理后的数据库输入至 DCNN 网络中开展相关的训练任务。

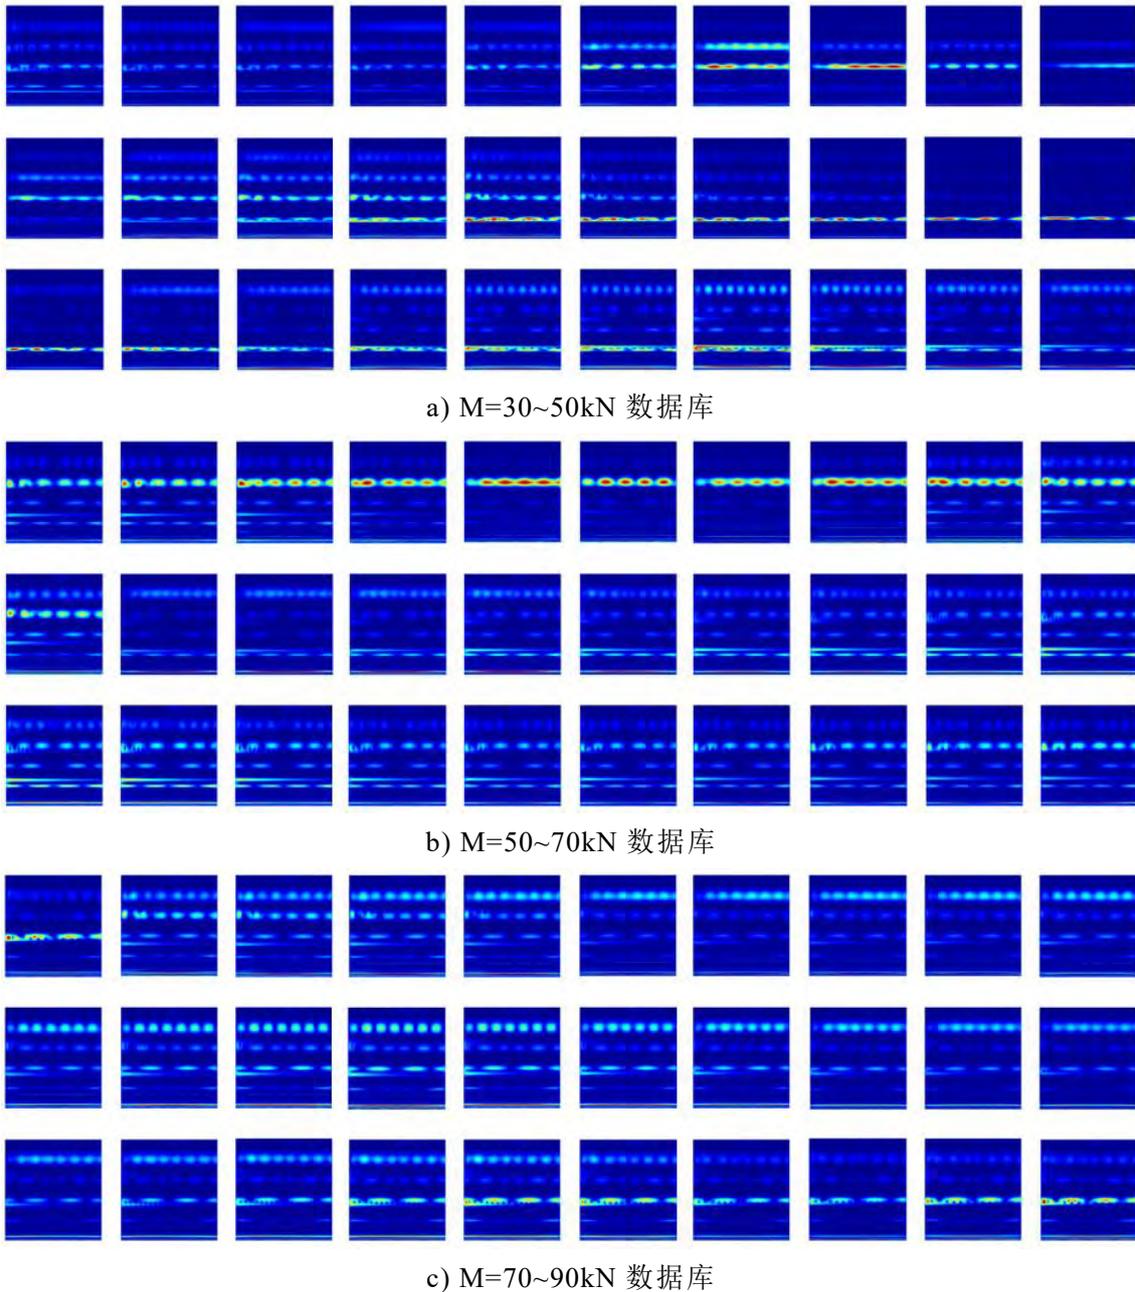


图 2.15 不同载重工况下简支梁模型响应数据库

在本研究过程当中，拟计划通过 DCNN 神经网络模型开展研究，对所提基于深度学习理论及结构特征响应提取的车辆荷载辨识方法的可行性进行测试。神经网络模型选取方面，为获取准确的车载信息识别效果，采用国际上所通用的大型深层 DCNN 网络模型来开展相关训练工作。考虑到以 GoogLeNet 及 ResNet 等为代表的大型深层 DCNN 网络模型神经元数量较多、模型结构较为复杂，导致其在训练过程中所需消耗的内存及时间成本过大，且对计算机的性能配置情况具有很高的要求。故在综合模型性能及计算效率后，最终选用 AlexNet 模型、并以迁移学习方式开展相关的训练任务。即在训练阶段首先加载经大型自然图像数据集 ImageNet^[102]预训练过的 AlexNet 模型，其中将低阶卷积层及池化层中的相关参数保持不变，仅将底端全连接层中的参数进行重置。同时，将试验过程中所提取到

的特征响应信息输入至经预训练过的 AlexNet 模型中，以开展相关测试任务，如图 2.16 所示。

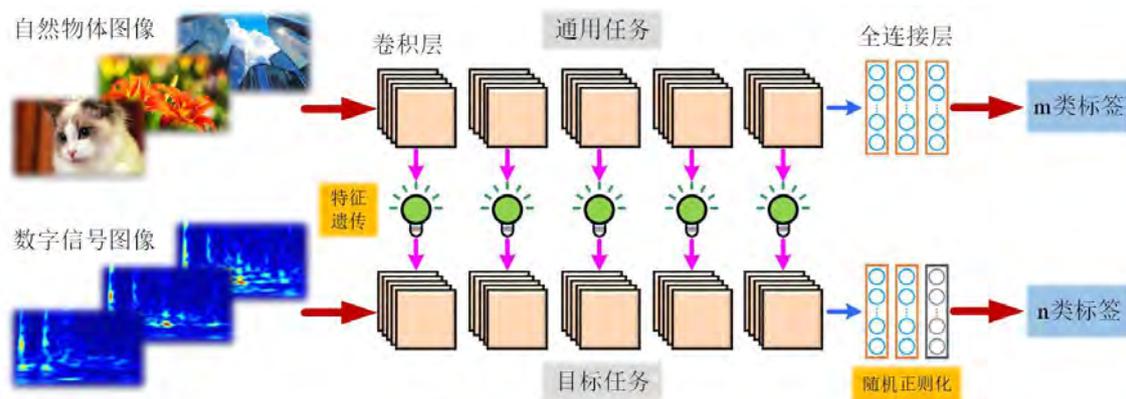


图 2.16 AlexNet 模型迁移学习示意图

神经网络模型训练方面，针对所建立的结构特征响应数据库，随机抽取各数据库中 70% 的样本用以进行模型训练任务，剩余的 30% 样本则作为测试集用以对神经网络的训练效果进行判定。这里，根据相关文献建议，定义动量常数为 0.9^[103]。其他训练参数配置方面，将每次训练迭代的最小批次设置为 64，最大迭代次数设置为 64，学习率设置为 0.0001。通过将所建立的数据结构、设置的训练参数及模型的训练方式等信息作为输入，实现对 DCNN 网络在该数据集上的训练任务。同时，通过改变训练数据集/测试数据集中样本构成情况的方式，先后进行了五次随机试验测试，以降低各种不确定性因素所可能导致的误差影响。试验过程中的模型准确率曲线及损失函数曲线如图 2.17 所示。可以看到，在迭代约 6 个训练周期后，训练所得的准确率曲线开始由 30% 逐渐上升至 80% 左右，相应的损失函数曲线则由 1.2 逐渐降低至 0.4 附近；在迭代约 75 个周期后，模型在该数据集上的训练准确率开始逐渐收敛在 99.68% 附近，相应的损失函数值则稳定在 0.011 左右。

将所建立的测试数据集输入至网络模型中，用以对训练效果进行测评。发现五次随机试验的平均测试精度约为 97.44%，表明经训练后的神经网络模型可基本实现对所测试车辆载重情况的分类识别。同时，将其中两次随机测试的识别结果以混淆矩阵形式进行表示，发现其能够较为准确地对各样本进行分类。最终，以有限元模拟分析的方式验证了所提基于深度学习理论及结构特征响应提取的车辆荷载信息辨识方法的可行性。除此之外，考虑到现有的 AlexNet 模型通常是由大型公开自然图像数据集 ImageNet 所预训练而成的，其所应用的场景也主要集中在对自然界真实物体的判断识别；对于本研究中所涉及的数字信号图像并未见相关报道，即深度 DCNN 网络模型在该类型数据集上的测试效果并不明确。然而测试结果表明，经大型自然图像数据集 ImageNet 训练过的 DCNN 模型，对于数字信号图像分类问题也具有较好地迁移学习适用性。

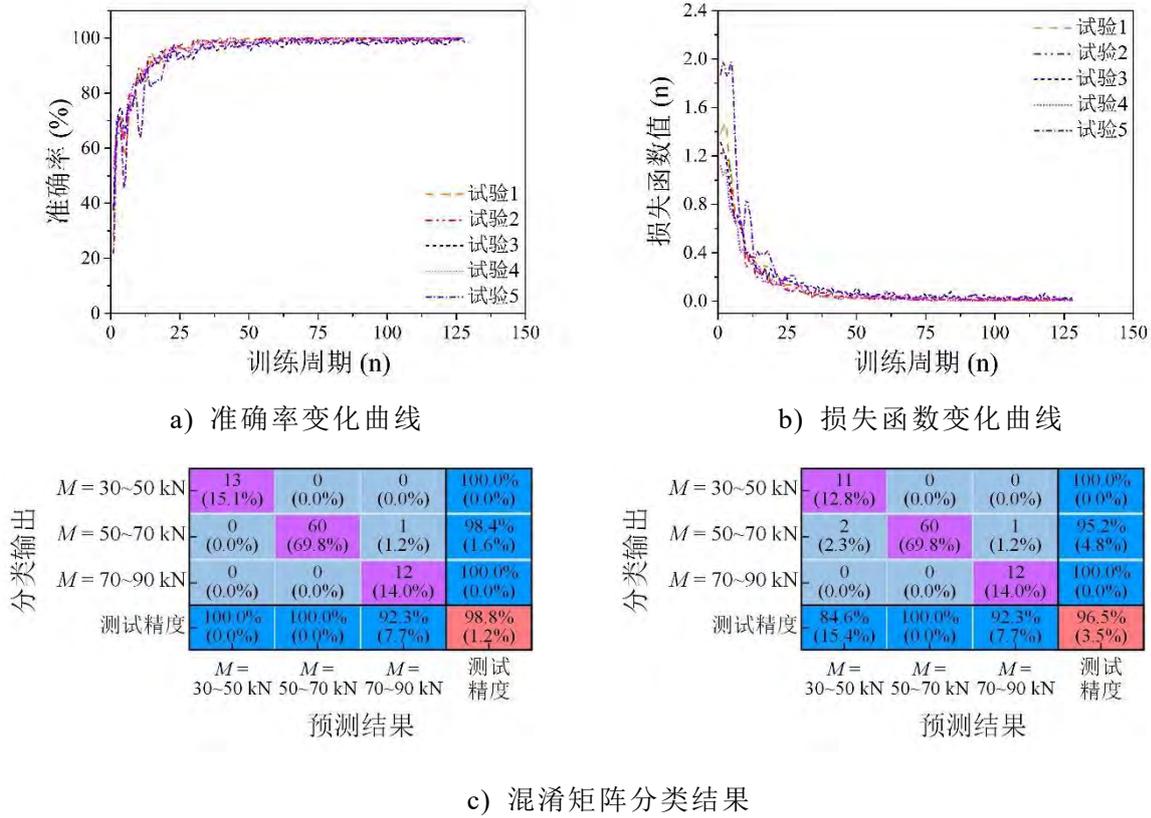


图 2.17 DCNN 网络模型训练结果

2.6.3.2 车速识别

通过开展模拟识别研究，对所提方法在车辆行驶速度识别方面的可行性进行探究。试验过程中，设置移动荷载的幅值为 50kN，并通过改变荷载移动速度 v 的方式，来实现对不同车速的模拟。其中，依次设置了 45~60km/h、60~75km/h 及 75~90km/h 三种测试工况。以模拟车速位于 60~75km/h 范围内的情况为例，通过以 0.05 km/h 的移动速度增量，建立了样本量为 300 次测试工况的结构响应数据库。数据处理方面，针对数值模拟计算所得的各结构时域响应信号，通过采用 STFT 变换、WVT 变换及 CWT 变换等时-频分析技术对其中所潜在的结构特征信息进行提取，处理结果如图 2.18 所示。可以发现处理结果与前述测试基本一致。因此，最终利用 CWT 变换对试验所得数据进行预处理分析，从而对结构加速度响应中的特征信息进行提取，并最终将其转化为二维平面图像进行深度学习训练任务。

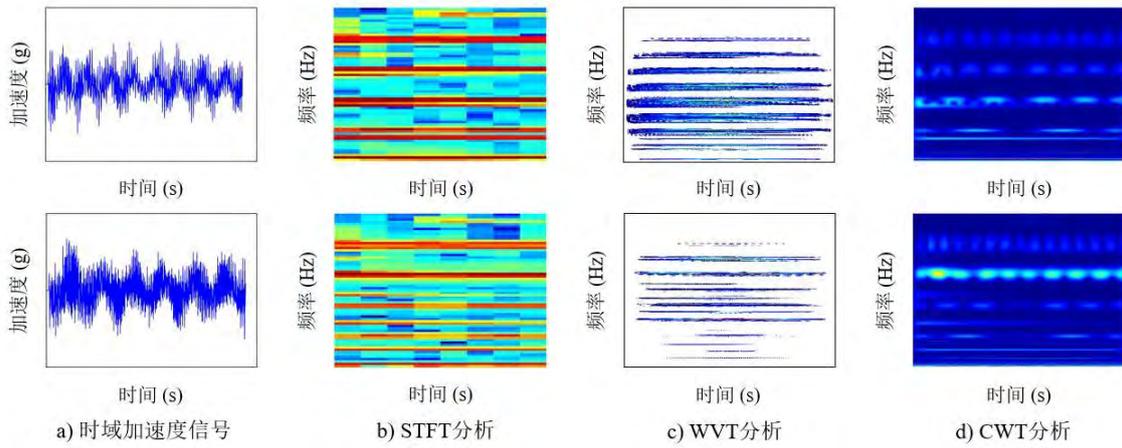
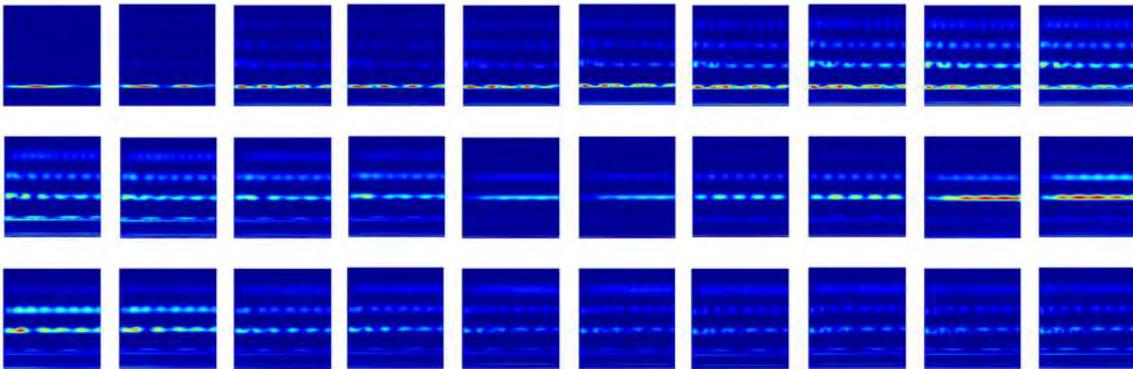
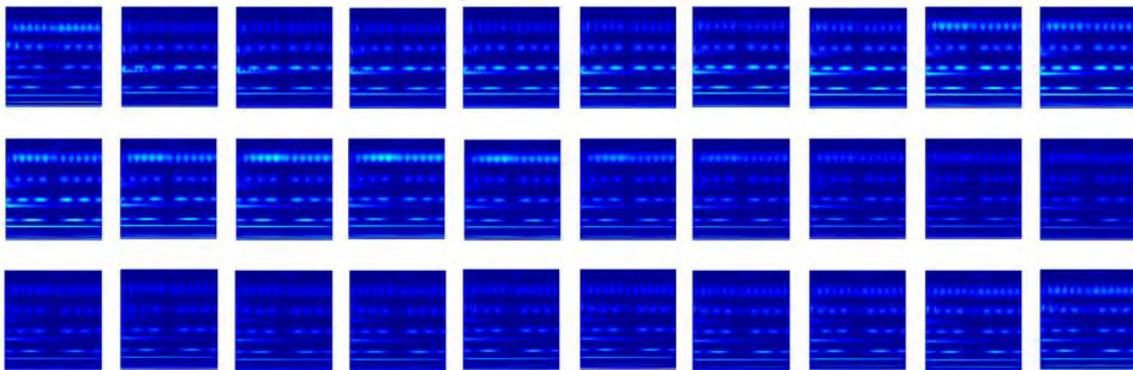


图 2.18 不同时-频分析技术提取特征响应信息对比

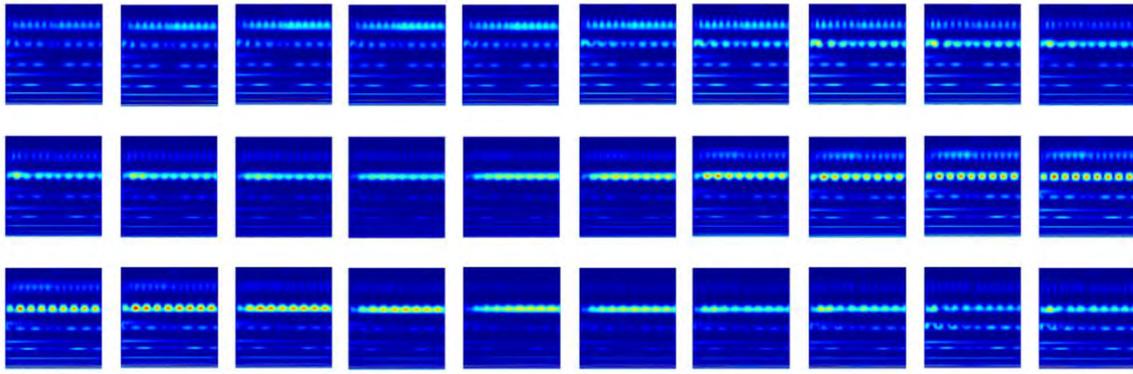
根据预设的试验测试方案，基于 DCNN 神经网络模型开展了相关研究分析工作。在经多工况测试建立结构响应数据库后，按照预设所属类别对其中的各样本进行分类标注。值得注意的是，由于神经网络模型中输入层对图像的像素规格具有特定要求，故需要通过编写程序将数据库中的各样本依次转换成 227×227 像素尺寸的图像形式，如图 2.19 所示。除此之外，为提高分析处理效率，利用程序语言将各样本统一调整为具有五位有效数字的图像格式，并通过在标注文件中定义每张图像所对应的测试工况类型，即可完成标注文件处理工作。最终，将整理后的数据库输入至神经网络中进行分类训练任务。



a) $v=45 \sim 60 \text{ km/h}$ 数据库



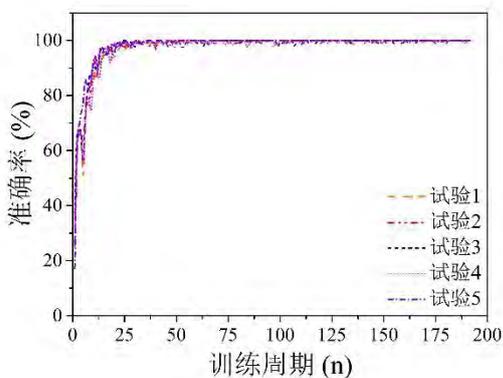
b) $v=60 \sim 75 \text{ km/h}$ 数据库



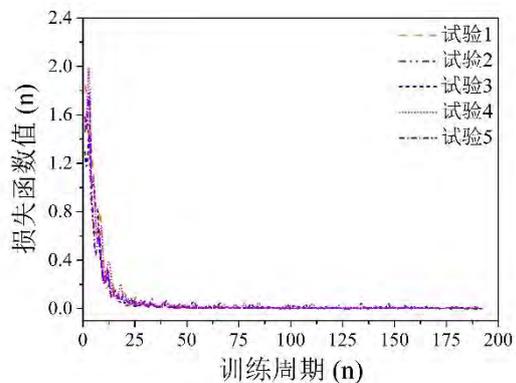
c) $v=75\sim 90\text{km/h}$ 数据库

图 2.19 不同速度工况下简支梁模型响应数据库

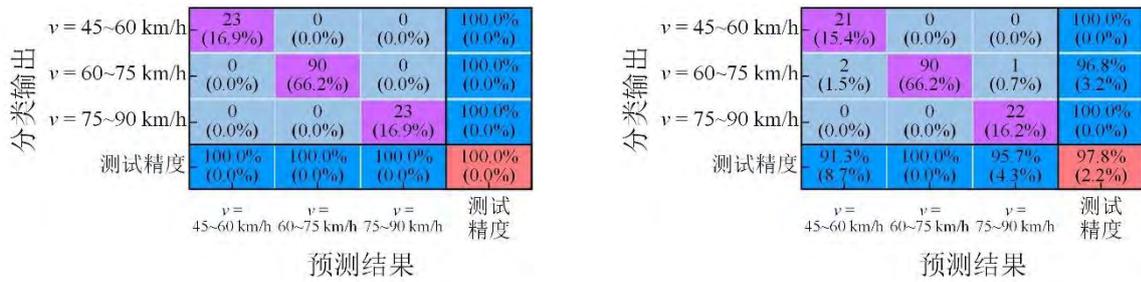
具体在神经网络设置方面，为减小计算输出结果与真实情况之间的误差累积程度，在模型反向传播阶段采用了具有动量的随机梯度下降算法，用以不断地进行迭代训练，从而在提高训练效率的基础上降低损失函数值。样本训练方面，随机选取各结构响应数据库中 70% 的样本作为训练集，剩余 30% 的样本则作为测试集用以对神经网络的训练效果进行精度评估。训练模式方面，所涉及到相关参数的设置情况均与前述试验保持一致。同时将数组结构样本、定义的模型训练参数以及预设的网络结构作为输入，对该 DCNN 网络模型进行训练。为避免样本偶然性所导致的误差影响，通过改变输入数据集的样本组成情况，共先后进行了五次随机测试。训练过程中的模型准确率曲线及损失函数曲线如图 2.20 所示。可以看到，在迭代约 10 个训练周期后，准确率曲线开始由 30% 逐渐提高至 85% 左右，相应的损失函数曲线则由 1.6 逐渐下降至 0.3 左右；在迭代约 75 个训练周期后，所训练模型的准确率开始逐渐稳定在 100% 附近，相应的损失函数值则稳定在 0.001 左右。最终，将预先设置好的测试集输入至网络模型中进行精度评估，发现试验 1~5 的平均测试精度约为 99.26%，表明经训练后的 DCNN 网络模型可基本实现对所测试车辆行驶速度的分类识别。



a) 准确率变化曲线



b) 损失函数变化曲线



c) 混淆矩阵分类结果

图 2.20 DCNN 网络模型训练结果

2.7 车-桥耦合振动模拟测试

2.7.1 车-桥耦合振动理论

为进一步验证所提车辆荷载识别方法的可行性，相应开展了更符合实际情况的车-桥耦合计算。其中，在车-桥耦合振动理论中，车辆模型与桥梁结构将通过相互作用关系耦合形成一个整体动力系统。基于车-桥接触点处的相互作用关系，可建立相应的运动动力学方程。同时，在进行一系列的时程计算分析后，即可获得桥梁结构在任意时刻下的动力响应。其中，在桥梁模型建立方面，现有的各种大型商业有限元软件均可实现对复杂桥梁结构有限元模型的建立；车辆模型建立方面，可基于 D'Alembert 原理或 Hamilton 原理等理论实现对车辆结构数值方程的建立。

值得注意的是，关于车辆模型建立方面，现有研究成果表明采用集中质量-弹簧-阻尼系统的车辆模型在耦合振动分析过程中可获取较为满意的计算结果，且可对车辆模型各部位的响应情况进行考虑^[104]。目前，在车-桥耦合振动分析研究领域内，国际上所通用的车辆动力学模型主要包括 Wang 等^[104]建议的三轴车模型(即 Wang-3 模型)和 Obrien 等^[105]建议的五轴车模型(即 Obrien-5 模型)。该类型模型中的车体部分由集中质量进行模拟，其对应匹配有具体的转动惯量参数；对于悬架-车轮部分，则由弹簧-阻尼系统进行考虑。其中，Wang-3 车辆模型的原型为美国 AASHTO 桥梁规范中较为常见的 HS20-44 货车^[106]，Obrien-5 车辆模型则更多地参考了欧洲卡车的数据统计结果^[107]。然而，截至目前中国尚未明确提出合适的车辆模型，相关科研问题中通常借鉴的是国外科研资料，对基于本国国情的科学问题研究可能并不适合。因此，邓露等^[108]通过参考《公路桥涵设计通用规范》(JTGD60-2015)中所涉及到的相关设计车辆荷载信息，针对我国车-桥耦合振动科学问题研究提出了相应适用的车辆动力学模型(即 China-5 模型)；同时，通过参考相关数据统计结果及调研资料报告，并在利用等效性分析原则的基础上，规定了相应车辆模型的几何尺寸、刚度及阻尼系数等物理参数取值情况。上述所涉

及到车辆模型示意图如图 2.21 所示，其相关参数取值汇总如表 2.1 所示。

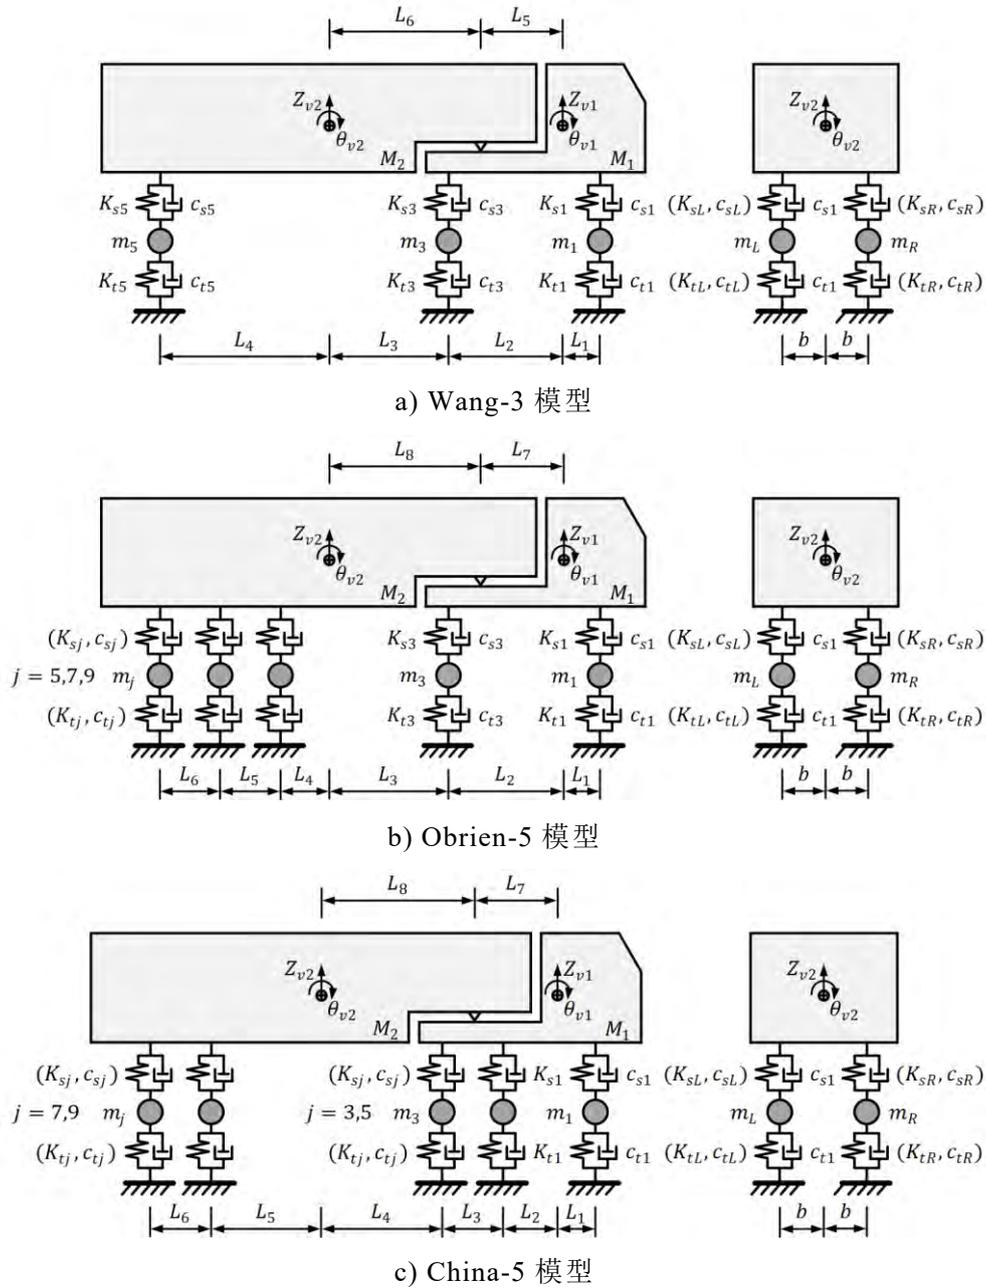


图 2.21 车-桥耦合分析常用车辆动力学模型

表 2.1 车-桥耦合分析常用车辆动力学模型参数取值

车辆模型	Wang-3	Obrien-5	China-5
轴数	3	5	5
几何尺寸 L_1 /(m)	1.698	0.500	1.000
几何尺寸 L_2 /(m)	2.569	2.500	2.000
几何尺寸 L_3 /(m)	1.984	3.800	1.400
几何尺寸 L_4 /(m)	2.283	1.300	3.800
几何尺寸 L_5 /(m)	2.215	1.100	1.800

(续表)

表 2.1 车-桥耦合分析常用车辆动力学模型参数取值

车辆模型	Wang-3	Obrien-5	China-5
几何尺寸 $L_6/(m)$	2.338	1.100	1.400
几何尺寸 $L_7/(m)$	--	4.150	2.700
几何尺寸 $L_8/(m)$	--	2.150	4.500
几何尺寸 $b/(m)$	1.100	--	0.900
车辆总重(t)	30676	323050	51823
车体 1 质量 $M_1/(t)$	2612	4500	2277
车体 2 质量 $M_2/(t)$	26113	314500	45246
车体 1 俯仰转动惯量 $I_{zx}^1/(kg*m^2)$	2022	4604	20196
车体 2 俯仰转动惯量 $I_{zx}^2/(kg*m^2)$	33153	16302	285990
车体 1 翻滚转动惯量 $I_{zy}^1/(kg*m^2)$	8544	--	2189
车体 2 翻滚转动惯量 $I_{zy}^2/(kg*m^2)$	181216	--	43512
车轴悬挂质量 $m_1/(kg)$	490	700	700
车轴悬挂质量 $m_3/(kg)$	808	1100	1000
车轴悬挂质量 $m_5/(kg)$	653	750	1000
车轴悬挂质量 $m_7/(kg)$	--	750	800
车轴悬挂质量 $m_9/(kg)$	--	750	800
悬架刚度 $K_{s1}, K_{s2}/(kN*m^{-1})$	243	400	300
悬架刚度 $K_{s3}, K_{s4}/(kN*m^{-1})$	1903	1000	1000
悬架刚度 $K_{s5}, K_{s6}/(kN*m^{-1})$	1969	750	1000
悬架刚度 $K_{s7} \sim K_{s10}/(kN*m^{-1})$	--	750	1250
悬架阻尼 $D_{s1}, D_{s2}/(kN*s*m^{-1})$	2	10	10
悬架阻尼 $D_{s3}, D_{s4}/(kN*s*m^{-1})$	8	10	53
悬架阻尼 $D_{s5}, D_{s6}/(kN*s*m^{-1})$	7	10	53
悬架阻尼 $D_{s7} \sim D_{s10}/(kN*s*m^{-1})$	--	10	53
轮胎刚度 $K_{t1}, K_{t2}/(kN*m^{-1})$	875	1750	1500
轮胎刚度 $K_{t3}, K_{t4}/(kN*m^{-1})$	3503	3500	3000
轮胎刚度 $K_{t5}, K_{t6}/(kN*m^{-1})$	3507	3500	3000
轮胎刚度 $K_{t7} \sim K_{t10}/(kN*m^{-1})$	--	3500	3000
轮胎阻尼 $D_{t1} \sim D_{t2}/(kN*s*m^{-1})$	2	--	3
轮胎阻尼 $D_{t7} \sim D_{t10}/(kN*s*m^{-1})$	--	--	3

2.7.1.1 桥梁振动方程

依据结构动力学理论易知，桥梁子系统的动力学方程可表示为^[109]：

$$[M_b]\{\ddot{U}_b\}+[C_b]\{\dot{U}_b\}+[K_b]\{U_b\}=\{F_b\} \quad (2.46)$$

其中, $[M_b]$ 、 $[C_b]$ 、 $[K_b]$ 分别表示桥梁结构的质量矩阵、阻尼矩阵和刚度矩阵; $\{F_b\}$ 表示桥梁结构因车辆荷载移动所产生的荷载向量; $\{U_b\}$ 表示桥梁结构在受到车辆荷载移动作用下所产生的结点位移向量。

对于车-桥耦合振动问题, 桥梁结构的质量矩阵 $[M_b]$ 及刚度矩阵 $[K_b]$ 均可由有限元模型计算分析直接进行求解; 而对于阻尼矩阵 $[C_b]$ 则可依据 Rayleigh 阻尼计算方法进行求解:

$$C_b = \frac{2\xi\omega_1\omega_2}{\omega_1+\omega_2}[M_b] + \frac{2\xi}{\omega_1+\omega_2}[K_b] \quad (2.47)$$

其中, ω_1 和 ω_2 分别表示桥梁结构的任意两阶频率, 通常情况下大多取为结构频率响应的第一、二阶; ξ 表示结构的阻尼比, 通常以现场桥梁的实际测试结果为依据进行确定。若按照经验值进行确定时, 则认为钢结构桥梁一般取 0.005~0.015, 钢-混组合桥梁一般取为 0.015~0.02, 混凝土桥梁则取为 0.02~0.03。

2.7.1.2 车辆振动方程

在车-桥耦合振动理论中, 车辆子系统通常被假定为刚体模型, 并依据实际情况分别设置有沉浮、点头及侧翻等三个自由度; 同时, 每个车轮也依次定义有一个沿竖直方向运动的自由度。因此, 对于一个含有 n 轴的车辆模型, 其总自由度数目为 $2n+3$ ^[110]。车辆子系统建模方面, 车体-车轮及车轮-桥面之间均通过弹簧与阻尼器进行连接。除此之外, 车辆的刚度系数、阻尼系数及悬挂系统均假定为线性物理参数。

依据结构动力学理论易知, 车辆子系统的动力平衡方程可表示为:

$$[M_v]\{\ddot{U}_v\}+[C_v]\{\dot{U}_v\}+[K_v]\{U_v\}=\{F_v\} \quad (2.48)$$

其中, $[M_v]$ 、 $[C_v]$ 、 $[K_v]$ 分别表示车辆子系统的质量矩阵、阻尼矩阵和刚度矩阵; $\{F_v\}$ 表示车辆子系统在运动过程中所受到的荷载向量; $\{U_v\}$ 表示车辆子系统所产生的位移向量。

相应地, 可针对车辆子系统的整体质量矩阵、位移向量及荷载向量等信息依次开展相应的求解过程。其分别汇总如式(2.49)~(2.51)所示。首先, 车辆子系统的质量矩阵可表示为:

$$\{M_v\} = \text{diag}\{m_s, J_y, J_x, m_{t1}, m_{t2}, m_{t3}, \dots, m_{t2n}\} \quad (2.49)$$

其中, $\text{diag}\{\dots\}$ 表示对角矩阵; m_s 表示车辆子系统的集中质量; J_x 、 J_y 分别表示车辆子系统沿横(纵)方向上的摆动惯量; m_{ti} 表示车辆子系统中第 i 个车轮所对应的质量。其次, 车辆子系统的位移向量可表示为:

$$\{U_v\} = \text{col}\{U_s, \theta_s, \alpha_s, U_{t1}, U_{t2}, \dots, U_{t2n}\} \quad (2.50)$$

其中, $\text{col}\{\dots\}$ 表示 $n \times 1$ 维矩阵; U_s 表示车辆子系统沿竖向振动的自由度; θ_s 表示车辆子系统的点头振动自由度; α_s 表示车辆子系统沿横向振动的自由度; U_{ti} 表示

车辆子系统中第*i*个车轮所对应的竖向振动自由度。同时，车辆子系统的荷载向量可表示为：

$$\{F_v\} = \text{col}\{0,0,0, k_{t1}\Delta_1 + c_{t1}\dot{\Delta}_1, k_{t2}\Delta_2 + c_{t2}\dot{\Delta}_2, \dots, k_{t2n}\Delta_{2n} + c_{t2n}\dot{\Delta}_{2n}\} \quad (2.51)$$

其中， k_{ti} 表示车辆子系统中第*i*个车轮所对应的等效弹簧刚度系数； c_{ti} 表示车辆子系统中第*i*个车轮所对应的阻尼系数； Δ_i 表示车辆子系统中第*i*个车轮与路面接触点之间所产生的相对位移。

若选择车辆子系统模型中的车身与轮胎之间连接部位的界线作为划分依据，对车辆结构的阻尼矩阵做分区运算，则将相应得到四个子矩阵。其可以具体表示为：

$$[C_v] = \begin{bmatrix} C_{v11} & C_{v12} \\ C_{v21} & C_{v22} \end{bmatrix} \quad (2.52)$$

其中，阻尼矩阵中参数 $[C_{v11}]$ 可表示为：

$$[C_{v11}] = \begin{bmatrix} \sum_i^n c_{s2i-1} + c_{s2i} & -\sum_i^n a_i(c_{s2i-1} + c_{s2i}) & -\sum_i^n (b_1 c_{s2i-1} + b_2 c_{s2i}) \\ -\sum_i^n a_i(c_{s2i-1} + c_{s2i}) & \sum_i^n a_i^2(c_{s2i-1} + c_{s2i}) & -\sum_i^n (b_1 a_i c_{s2i-1} + b_2 a_i c_{s2i}) \\ -\sum_i^n (b_1 c_{s2i-1} + b_2 c_{s2i}) & -\sum_i^n (b_1 a_i c_{s2i-1} + b_2 a_i c_{s2i}) & \sum_i^n (b_1^2 c_{s2i-1} + b_2^2 c_{s2i}) \end{bmatrix} \quad (2.53)$$

阻尼参数 $[C_{v12}]$ 可表示为：

$$[C_{v12}] = \begin{bmatrix} -c_{s1} & -c_{s2} & \dots & -c_{s2n} \\ a_1 c_{s1} & a_1 c_{s2} & \dots & a_n c_{s2n} \\ -b_1 c_{s1} & -b_2 c_{s2} & \dots & -b_2 c_{s2n} \end{bmatrix} \quad (2.54)$$

阻尼参数 $[C_{v21}]$ 可表示为：

$$[C_{v21}] = \begin{bmatrix} -c_{s1} & a_1 c_{s1} & -b_1 c_{s1} \\ -c_{s2} & a_1 c_{s2} & -b_2 c_{s2} \\ \vdots & \vdots & \vdots \\ -c_{s2n} & a_n c_{s2n} & -b_1 c_{s2n} \end{bmatrix} \quad (2.55)$$

阻尼参数 $[C_{v22}]$ 可表示为：

$$[C_{v22}] = \begin{bmatrix} c_{s1} + c_{t1} & 0 & \dots & 0 \\ 0 & c_{s2} + c_{t2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & c_{s2n} + c_{t2n} \end{bmatrix} \quad (2.56)$$

其中， c_{si} 表示车辆子系统中第*i*个车轮所对应等效悬挂系统的阻尼系数； a_i 表示车辆子系统中第*i*个车轮沿车身长度方向距车体重心的水平距离； b_i 表示车辆子系统中第*i*个车轮沿车身宽度方向距车体重心的水平距离；参数*i*的初始值取为 1。

同理，车辆子系统的刚度矩阵计算方面，只需将公式(2.53)~(2.56)中的阻尼参数*C*相应替换为刚度参数*K*即可。若当桥梁结构上同一时刻有多个车辆模型共同作用时，则需要将上述车辆子系统的相关参数矩阵进行重构，从而得到包含多个车辆子系统在内的整体质量矩阵、阻尼矩阵和刚度矩阵。假设某一时刻桥面上共存在有*N*个车辆，则可按照等效原理将其视为一个包含多个车轴在内的单体车辆，其相应的车轴数目为：

$$n_{all} = \sum_{i=1}^N n_i \quad (2.57)$$

其中， n_{all} 表示包含所有车辆模型在内的车轴总数量； n_i 表示第*i*个车辆所对应的车轴总数量。

2.7.1.3 车-桥耦合振动方程

车-桥耦合振动模型通常由车辆子系统和桥梁子系统组成。通常情况下，车辆子系统一般由结构动力学方法进行建立，桥梁子系统则多由有限元方法进行建模。两个子系统通过相互作用关系，从而耦合形成统一整体。对于车-桥耦合系统而言，其外部激励源主要包括风载、地震作用、船舶撞击等，内部激励源则主要由路面粗糙度所引起的车辆颠簸效应^[111]。以车-桥轮轨接触面为界，针对车辆子系统及桥梁子系统分别建立动力学方程，并通过两者之间轮轨接触位置处的位移协调方程及相互作用力关系进行整体系统耦合。假设桥梁及车辆的结点位移分别为 Y 、 Z ，则依据 D'Alembert 理论可建立相应的结构动力学方程^[111]：

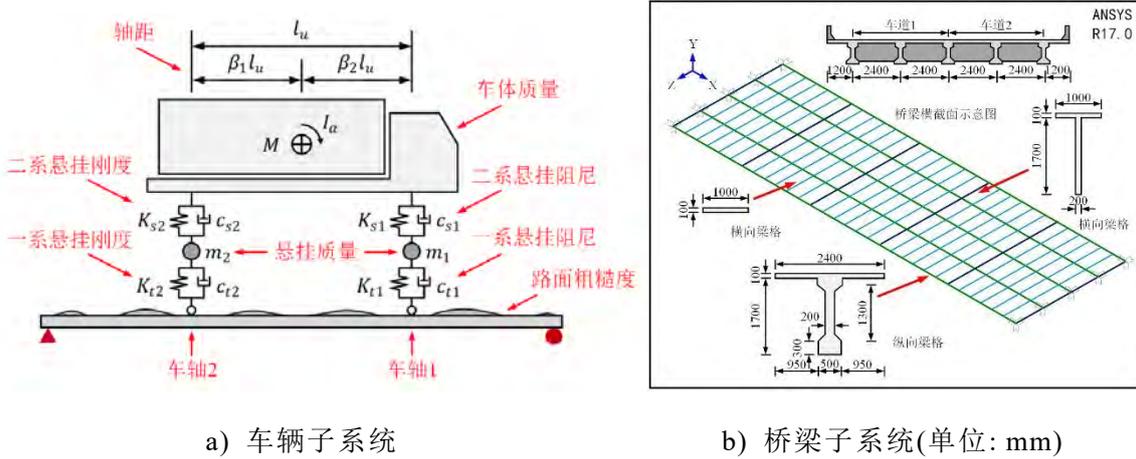
$$\begin{cases} M_b\{\ddot{Y}\} + C_b\{\dot{Y}\} + K_b\{Y\} = \{F_{bv}\} \\ M_v\{\ddot{Z}\} + C_v\{\dot{Z}\} + K_v\{Z\} = \{F_{vb}\} + \{F_{vg}\} \end{cases} \quad (2.58)$$

其中， M_b 、 M_v 、 C_b 、 C_v 、 K_b 、 K_v 分别对应于桥梁(车辆)子系统的整体质量矩阵、阻尼矩阵及刚度矩阵； $\{\ddot{Y}\}$ 、 $\{\ddot{Z}\}$ 、 $\{\dot{Y}\}$ 、 $\{\dot{Z}\}$ 分别表示相应的加速度向量及速度向量； $\{F_{vg}\}$ 表示由车辆自身重量所产生的等效结点荷载向量； F_{bv} 、 F_{vb} 为一对相互作用力，表示车-桥接触点处所产生的作用力在经形函数分配后，其桥梁及车辆模型中各结点所得到的荷载向量。

2.7.2 车-桥耦合振动测试

2.7.2.1 车-桥耦合模型建立

通过采取有限元数值模拟计算，对所提基于深度学习理论及结构特征响应提取的车载信息识别技术的可行性进行测试。针对耦合振动计算方面，采用混合建模方式建立了车-桥耦合振动有限元模型；并通过基于垂直方向车-桥接触点处的动力学理论，推导了车-桥系统的耦合振动方程。车辆子系统建模方面，利用 MATLAB 平台编写了相应的结构动力方程。其中车辆子系统采用两系悬挂的二轴半车模型，如图 2.22(a)所示，其对应于实际情况下的两轴载货卡车。车辆模型的其他相关参数汇总如表 2.2 所示。桥梁子系统建模方面，利用 ANSYS 平台建立了桥梁结构的有限元模型。其中模型采用梁格法进行建立，如图 2.22(b)所示，其对应于实际情况下的钢筋混凝土梁板式桥梁结构。桥梁模型参数设置方面，结构全长约为 30m，宽度约为 12m。横截面各 T 型梁的抗弯刚度 $EI=1.08\times 10^{10}\text{N}\cdot\text{m}^2$ ，线密度 $\rho_l=1.87\times 10^3\text{kg}/\text{m}^3$ ，阻尼系数 $\alpha=0.80$ 、 $\beta=7.3\times 10^{-4}$ 。每隔 6m 设置有横隔板进行连接。该桥梁结构设置有两个车道，分别将其记为车道 1 及车道 2。经模态计算分析后，得到该简支桥梁有限元模型的前三阶振动频率分别为 $f_1=2.62\text{Hz}$ ， $f_2=10.46\text{Hz}$ ， $f_3=23.43\text{Hz}$ 。



a) 车辆子系统

b) 桥梁子系统(单位: mm)

图 2.22 车-桥耦合振动有限元模型建立

表 2.2 模拟所用车辆模型参数取值^[111]

车辆模型	悬挂质量 $m/(kg)$	一系悬挂刚度 $K_t/(N/m)$	一系悬挂阻尼 $c_t/(kg/s)$	二系悬挂刚度 $K_s/(N/m)$	一系悬挂阻尼 $c_s/(kg/s)$
前轴	1,450	3.95×10^6	0	1.46×10^6	4,379
后轴	1,450	9.47×10^6	0	3.94×10^6	14,363

注:车体总重 $M=2.5 \times 10^4$ kg, 转动惯量 $I_\alpha=1.72 \times 10^5$ kg*m²。

基于结构动力学理论, 针对所建立的车辆子系统有限元模型, 可依次结构振动方程中的质量矩阵、阻尼矩阵及刚度矩阵进行确定^[111]。其中, 质量矩阵可表示为:

$$[M_v] = \begin{bmatrix} m_1 & 0 & 0 & 0 \\ 0 & m_1 & 0 & 0 \\ 0 & 0 & M\beta_2^2 + I_\alpha/l_u^2 & M\beta_1\beta_2 - I_\alpha/l_u^2 \\ 0 & 0 & M\beta_1\beta_2 - I_\alpha/l_u^2 & M\beta_1^2 + I_\alpha/l_u^2 \end{bmatrix} \quad (2.59)$$

阻尼矩阵可表示为:

$$[C_v] = \begin{bmatrix} c_{s1} + c_{t1} & 0 & -c_{s1} & 0 \\ 0 & c_{s2} + c_{t2} & 0 & -c_{s2} \\ -c_{s1} & 0 & c_{s2} & 0 \\ 0 & -c_{s2} & 0 & c_{s2} \end{bmatrix} \quad (2.60)$$

刚度矩阵可表示为:

$$[K_v] = \begin{bmatrix} k_{s1} + k_{t1} & 0 & -k_{s1} & 0 \\ 0 & k_{s2} + k_{t2} & 0 & -k_{s2} \\ -k_{s1} & 0 & k_{s2} & 0 \\ 0 & -k_{s2} & 0 & k_{s2} \end{bmatrix} \quad (2.61)$$

同时, 由车辆自身重量所产生的等效结点荷载向量可表示为:

$$\{F_{vg}\} = \{m_1g \quad m_2g \quad Mg\beta_2 \quad Mg\beta_1\}^T \quad (2.62)$$

对于车-桥接触点之间的相互作用力, 经在经形函数运算处理后, 被分配至车辆各结点上的荷载向量可表示为:

$$\{F_{vb}\} = \{k_{t1}y_1 + c_{t1}\dot{y}_1 \quad k_{t2}y_2 + c_{t2}\dot{y}_2 \quad 0 \quad 0\}^T \quad (2.63)$$

根据式(2.59)~(2.63)可知,车-桥耦合振动体系中车辆及桥梁子系统的质量矩阵、阻尼矩阵和刚度矩阵均为一常数,仅与结构本身的材料性质及架构设置有关;而相互作用力向量 $\{F_{bv}\}$ 及 $\{F_{vb}\}$ 则随车辆移动位置而发生实时变化。

关于车-桥接触点处的位移及速度求解方面,首先需要确定车辆模型中车轮的实时坐标位置。根据结构动力学理论可知,在已知车辆行驶初速度 v_0 、运动过程中的加速度 a 以及行驶时间 t 的情况下,可利用车辆系统在行驶过程中的起始节点 A 及终止节点 B 等信息,求解获得车辆模型中各车轮的实时坐标位置。对于本问题研究中所使用的车辆子系统模型,其各车轮的坐标位置表达式如下:

$$\begin{cases} c_{1x} = A_x + z_{jl}(B_x - A_x)/l_c \\ c_{1y} = A_y + z_{jl}(B_y - A_y)/l_c \\ c_{1z} = A_z + z_{jl}(B_z - A_z)/l_c \\ c_{2x} = c_{1x} - (b_1 + b_2)(B_x - A_x)/l_c \\ c_{2y} = c_{1y} - (b_1 + b_2)(B_y - A_y)/l_c \\ c_{2z} = c_{1z} - (b_1 + b_2)(B_z - A_z)/l_c \end{cases} \quad (2.64)$$

其中, c_{ij} 表示车辆模型中各车轮在任意时刻的坐标位置,且 i 、 j 分别表示车轮编号及相应坐标方向; l_c 表示在任意时刻下由起始结点至终止结点之间的位置距离,其数值大小等于 $\sqrt{(A_x - B_x)^2 + (A_y - B_y)^2 + (A_z - B_z)^2}$; z_{jl} 表示车辆模型在任意时刻距初始位置的相对距离,其数值大小等于 $v_0 t + at^2/2$ 。

在计算获取车辆模型中各车轮在任意时刻 t 下的坐标位置后,需对车轮与桥面接触位置处的运动方程进行求解。若车轮在该时刻处于桥梁节点上时,即依据该节点进行运动状态分析;若车轮未处在桥梁节点上时,相应的接触点运动状态则将基于相邻节点 a 与 b 的运动状态进行线性组合,如图 2.23(a)所示,其可表达为:

$$f(x) = (1 - 3\xi^2 + 2\xi^3)f_a + l(\xi - 2\xi^2 + \xi^3)\theta_a + (3\xi^2 - 2\xi^3)f_b + l(\xi^3 - \xi^2)\theta_b \quad (2.65)$$

其中, $f(x)$ 表示所产生的相关位移函数;参数 f_a 、 f_b 、 θ_a 、 θ_b 分别表示桥梁单元两端结点处所产生的挠度及转角信息; l 表示所在梁单元所对应的长度;同时,计算系数 $\xi = x/l$ 。

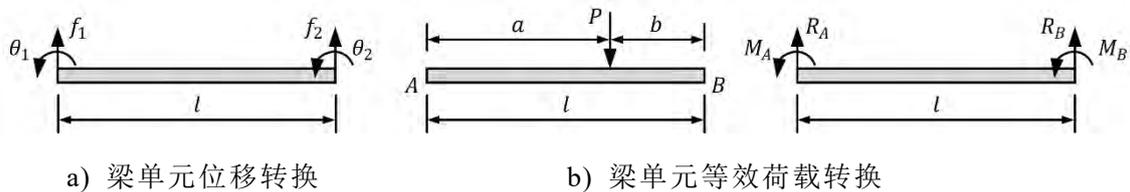


图 2.23 有限元模型位移/荷载转换示意图

车辆子系统荷载向量 F_{vb} 及桥梁子系统荷载向量 F_{bv} 求解方面,首先需对任意时刻 t 下车辆-桥梁子系统之间的相互作用力 $F(t)$ 进行求解。具体可按照下式进行计算:

$$F(t) = (D_c(t) - (D_Q(t) + W))K + (V_c(t) - V_Q(t))C \quad (2.66)$$

其中， $D_c(t)$ 表示任意时刻 t 下车-桥接触点处车轮所产生的瞬时位移； $D_Q(t)$ 表示时刻 t 作用下车-桥接触点处桥梁结构所产生的瞬时位移； W 表示时刻 t 作用下车轮所在位置处的路面粗糙度情况； K 表示车轮所对应的等效刚度系数； $V_c(t)$ 表示时刻 t 作用下车-桥接触点处车轮所对应的瞬时速度； $V_Q(t)$ 表示时刻 t 作用下车-桥接触作用点处桥梁结构所对应的瞬时速度； C 表示车轮所对应的等效阻尼系数。在该式中，瞬时速度 $V_c(t)$ 、 $V_Q(t)$ 均可基于瞬时位移 $D_c(t)$ 、 $D_Q(t)$ 的数值解通过一阶三点数值微分方程进行近似求解。

在此基础上，还需将车-桥接触作用点处所产生的相互关系等效转换至距车轮位置最近的桥梁单元结点处。针对本桥梁模型中所使用的梁单元而言，可依据荷载等效原理进行作用力转换，如图 2.23(b)所示，具体过程可表示如下：

$$W^e = \int_l \bar{p}(x)v(x)dx = \left[\int_l \bar{p}(x)N(x)dx \right] q^e = [R_A \ M_A \ R_B \ M_B] q^e \quad (2.67)$$

其中， W^e 表示该单元在外部荷载下所对应产生的功率； $\bar{p}(x)$ 表示外部荷载的密度函数； $v(x)$ 表示结点位移函数； $N(x)$ 表示该单元的形函数矩阵； q^e 表示结点位移向量； R_A 、 R_B 、 M_A 、 M_B 分别表示外部荷载 P 在梁端所产生的等效竖向力及等效弯矩，其可具体表示如下：

$$\begin{cases} R_A = -(Pb^2/l^3)/(3a+b), M_A = -Pab^2/l^2 \\ R_B = -(Pa^2/l^3)/(a+3b), M_B = Pa^2b/l^2 \end{cases} \quad (2.68)$$

其中， a 、 b 分别表示荷载 P 距梁单元两端结点 A 、 B 之间的位置信息； l 表示以 A 、 B 为端部结点的梁单元长度。

2.7.2.2 路面粗糙度模拟

作为车-桥耦合振动系统的主要内部激励源，路面粗糙度是一种平稳的、各态均历经零均值的随机高斯过程。依据现有研究成果可知，相关学者通常是利用确定性函数对路面粗糙度的概率分布情况进行函数表达。一般情况下，多采用功率谱密度函数(Power spectral density, PSD)模拟路面粗糙度。其通过对实际路面进行现场测量后，即可获得对应的路面粗糙度功率谱密度，并经数值拟合后便能得到对应的 PSD 曲线。相关学者基于大量测试统计结果，发现实际路面的粗糙程度与 PSD 曲线之间存在着明显的映射关系^[112]，因此可基于路面 PSD 函数，通过设置不同的标准级别用以实现对路面粗糙程度的分类。

在进行路面粗糙度研究时，国内外众多学者主要遵循了 ISO-1972 及 ISO-1984 两个标准规范。本研究主要依据了 ISO-1972 规范中所建议的标准要求，对路面粗糙度进行了数值模拟计算。其相应的 PSD 函数表达式为^[112]：

$$G_q(\Omega) = \begin{cases} G_q(\Omega_0) \left(\frac{\Omega}{\Omega_0}\right)^{-\omega_1} & \Omega \leq \Omega_0 \\ G_q(\Omega_0) \left(\frac{\Omega}{\Omega_0}\right)^{-\omega_2} & \Omega > \Omega_0 \end{cases} \quad (2.69)$$

其中， Ω 表示空间采样频率； Ω_0 表示标准空间采样频率，其物理含义表示为空间