

第3章 服装流行趋势分析AI应用

【教学内容】

服装流行趋势基本概念；服装解析深度学习模型；服装部件分类；服装色彩聚类。

【教学要求】

了解服装流行趋势基本概念；理解常用的服装解析深度学习模型；理解服装部件分类基本原理；理解服装色彩聚类基本原理；掌握常用服装解析深度学习模型应用方法；掌握服装部件分类应用方法；掌握服装色彩聚类应用方法。

【本章重点和难点】

[重点] 服装部件分类；服装色彩聚类。

[难点] 服装解析深度学习模型。

在当今社会,时尚已经不仅仅是简单的穿着,而是成为一种表达个性和态度的方式。随着科技的迅速发展,人工智能在各个领域都展现出了巨大的潜力,时尚产业也不例外。本章将探讨如何利用人工智能技术来分析服装流行趋势,揭示潮流的变迁规律,以及如何更好地满足消费者的需求。

时尚行业一直在不断变化和演进,而人工智能的介入为这种变革带来了全新的可能性。通过大数据分析、图像识别、自然语言处理等技术手段,人工智能能够深入挖掘海量的时尚数据,并从中提取出有价值的信息。这些信息不仅可以帮助设计师更好地把握时尚趋势,还能够帮助品牌更精准地进行市场定位,满足不同消费群体的需求,如图 3.1 所示。



图 3.1 服装中的 AI

服装解析深度学习模型是一种基于 CNN(卷积神经网络)等深度学习技术,对服装图像进行分类、目标检测和生成的模型。通过训练模型,它可以识别服装类别、定位服装物体位置、生成逼真的服装图像,并且通常利用迁移学习在相对较少的数据上进行训练。这些模型在电子商务推荐、虚拟试衣间开发以及时尚趋势分析等领域有着广泛的应用,为用户提供个性化、智能化的服装解决方案。

本章将首先介绍服装流行趋势基本概念,接着介绍服装解析深度学习模型,随后将详细介绍服装部件分类、服装色彩聚类,最后将展望未来,探讨人工智能可能带来的深远影响,以及时尚产业如何更好地利用人工智能来推动创新发展。通过本章阐述,读者将能够更全面地了解人工智能在时尚产业中的应用价值,以及如何利用人工智能技术来抓住时尚潮流的脉搏,实现商业和创新的双赢。

3.1 基本概念

3.1.1 服装流行趋势基本概念

服装流行趋势基本概念涵盖了时尚产业中的核心要素,包括周期性变化、季节流行、潮流元素、社会文化影响、消费者需求、设计创新以及数字化和社交媒体的影响等。深入理解这些概念不仅有助于把握时尚产业的发展动向,还能指导设计、生产、营销等各个环节的工作,从而实现更精准的市场定位、更具吸引力的产品设计,以及更有效的品牌推广策略。具体如下。

(1) 时尚周期: 时尚产业的变化具有周期性,从新颖到过时再到复兴,形成了不断循环的时尚周期。这种周期性变化反映了人们对于审美、文化和社会需求的变迁。

(2) 季节流行: 时尚产业通常按照春夏、秋冬等季节进行设计和发布,季节流行趋势反映了不同季节中人们对于服装风格、颜色和材质的偏好。

(3) 潮流元素: 每个时代都会有独特的潮流元素,如特定的服装款式、图案、颜色、面料等,这些元素在一段时间内成为流行趋势的代表。

(4) 社会文化影响: 社会文化因素对服装流行趋势有着深远的影响。时尚产业常常受到历史、艺术、流行文化、体育等方面的影响,从而塑造出不同的时尚风格。

(5) 消费者需求: 消费者需求是驱动时尚产业发展的关键因素之一。了解消费者的喜好、生活方式和购买习惯,有助于预测和满足市场需求。

(6) 设计创新: 时尚产业不断追求设计创新和突破,通过引入新的设计理念、技术和材料,推动时尚流行趋势的发展。

(7) 数字化和社交媒体影响: 随着数字化技术和社交媒体的普及,消费者获取时尚信息的渠道变得多样化,这对服装流行趋势的形成和传播产生了深远影响。

综上所述,深入理解这些基本概念,对于把握时尚产业动向,指导设计、生产、营销各环节工作具有重要意义。

3.1.2 服装解析深度学习模型基本概念

服装解析是一种特定形式的语义分割,旨在用细粒度语义将服装图像分割成多个部分,为图像中的每个像素分配服装项目或者背景的语义标签。与一般的物体或场景分割问题不同,由于服装自身固有属性繁多,存在纹理、款式、面料、颜色等多种特征,且细粒度的服装分类需要基于服装的语义、人体姿势的可变性和潜在的大量类别,服装解析需要更高层次的决策,如图 3.2 所示。




图 3.2 服装解析基本概念

3.2 各种解析算法模型

3.2.1 Fast R-CNN

Fast R-CNN(fast region-based convolutional neural network)是一种用于目标检测的深度学习模型,它在 R-CNN 模型的基础上进行了改进,以提高速度和性能。

Fast R-CNN 的主要改进包括以下几点:

(1) 区域提议网络(region proposal network, RPN): Fast R-CNN 将 RPN 集成到网络中,与分类和边界框回归共同训练,可以同时生成候选区域和对应的目标检测结果。这样就不需要像 R-CNN 那样使用选择性搜索等算法生成候选区域,大大提高了速度。

(2) ROI Pooling 层: Fast R-CNN 引入了 ROI(region of interest) Pooling 层,通过将不同大小的特征图区域映射到固定大小的特征图上,实现了对不同大小的区域进行精确的特征提取。

(3) 模型训练: Fast R-CNN 将区域提议网络(RPN)和目标检测网络(CNN)整合到一个单一的网络结构中,并进行端到端的训练,使得模型的训练更加简单和高效。

Fast R-CNN 相对于传统的 R-CNN 模型,在准确性和速度上都有明显的提升。它将目标检测任务分为两个阶段:首先使用 RPN 生成候选区域,然后使用 ROI Pooling 层和全连接层进行分类和边界框回归,从而实现了快速而准确的目标检测。

Fast R-CNN 网络有两个并行的输出分支,对于每个 ROI,第 1 个分支计算 k 个目标类别+1 个背景类别的分类概率 $p=(p_0, \dots, p_k)$,这 $k+1$ 个分类概率一般是通过在全连接层之后计算 softmax 得到的。第 2 个输出分支计算候选框归一化的偏移量和缩放尺度,把第 k 个类别对应的归一化的偏移量和缩放尺度记为 $t^k=(t_x^k, t_y^k, t_w^k, t_h^k)$,对于每个 ROI,通

过式(3.1)计算分类和位置回归的联合损失,即

$$L(p, u, t^u, v) = L_{\text{cls}}(p, u) + \lambda [u \geq 1] L_{\text{loc}}(t^u, v) \quad (3.1)$$

式中, $L_{\text{cls}}(p, u) = -\log p_u$ 为分类损失。

其中 u 表示真实的类别; 位置损失 $L_{\text{loc}}(t^u, v)$ 表示对于类别 u , 真实的归一化偏移量及缩放尺度元组 u_x, u_y, u_w, u_h 与实际预测的归一化偏移量及缩放尺度元组 $t^u = (t_x^u, t_y^u, t_w^u, t_h^u)$ 之间的差异, 通常可以用两个元组之间的 L 距离来度量。

贾梦林(Menglin Jia)提出了一种数据驱动的方法来识别时尚属性——Fast R-CNN 模型的修改版本, 在具有 594 个细粒度属性的大规模本地化数据集中的图像上进行训练, 这些图像来自不同场景, 如在线商店和街道快照。然后, 该模型将用于检测服装项目, 并对 T 台照片和时尚插图的服装属性进行分类。该研究首先主要基于 Fast R-CNN 来生成服装建议和类别分类, 并且添加了额外的分支来进行属性检测。其次, 在不同的领域测试模型。再利用深度网络从图像中提取服装属性, 创建服装风格集群的视觉嵌入, 研究全球服装流行趋势。该研究使用 DeepFashion(类别和属性预测基准)作为模型。再进行数据集修改(标记问题)与模型的架构——ResNet 101 和 RoI-Align 扩展了 Fast R-CNN 对象检测框架, 并进行了两处修改: 一个修剪机制和附加的平行于类别分支的服装属性分支, 如图 3.3 所示。

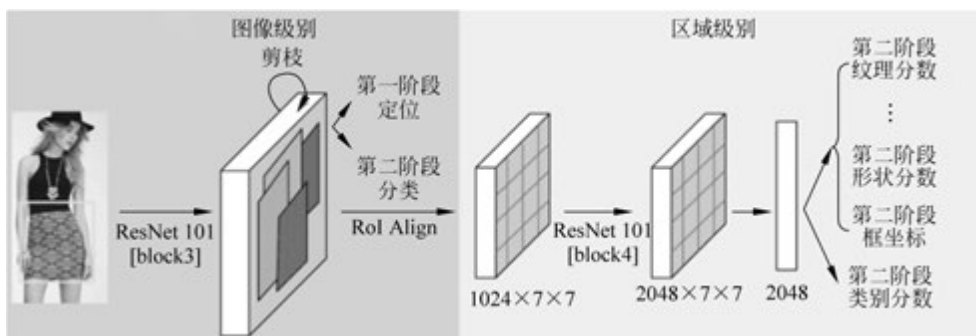


图 3.3 服装属性分支

贾梦林提出的数据驱动方法是基于深度学习技术, 特别是 CNN 的 Fast R-CNN 模型的改进版本, 用于识别时尚属性。这种方法的核心在于利用大量的标注数据来训练模型, 使其能够自动识别和分类时尚图片中的各种属性, 如颜色、纹理、款式等。

在传统的 Fast R-CNN 模型中, 模型首先需要生成候选区域, 然后对这些区域进行分类和边界框回归。而贾梦林提出的改进版本, 在以下几个方面进行了优化和改进。

(1) 数据增强: 为了提高模型的泛化能力和准确性, 可以通过数据增强技术(如随机裁剪、翻转、缩放等)来扩充训练数据集, 使模型能够学习到更加丰富的特征表示。

(2) 特征提取: 可能会采用更加先进的骨干网络(如 ResNet、VGG 等)来提取图像特征, 这些预训练的网络在大型数据集(如 ImageNet)上已经证明了其强大的特征提取能力。

(3) 多任务学习: 在识别时尚属性的同时, 模型可能还会进行其他相关任务的学习, 如服装分类、风格识别等, 通过多任务学习提高模型的综合性能。

(4) 注意力机制: 引入注意力机制可以帮助模型更好地关注图像中的关键部分, 从而提高对时尚属性的识别精度。



(5) 损失函数和优化算法：可能会采用特定的损失函数(如交叉熵损失、IoU 损失等)和优化算法(如 SGD、Adam 等)来优化模型的训练过程,使得模型能够更快地收敛并提高识别准确率。

(6) 模型融合：通过将多个模型的预测结果进行融合,可以进一步提高识别的准确性和鲁棒性。

通过这些改进,贾梦林提出的 Fast R-CNN 模型的修改版本能够在时尚属性识别任务上取得更好的性能。这种方法的应用不仅限于时尚领域,也可以扩展到其他需要图像识别和分类的领域,如无人驾驶、安防监控等。随着深度学习技术的不断进步,人们期待未来会有更多创新的方法被提出,以解决实际问题。

3.2.2 改进的服装解析方法

为了改进自动化服装推荐系统中的服装解析方法,特别是在处理纹理复杂服装时的准确性问题,李健书(Li)等人提出了一种新的方法。这种方法的核心在于不依赖于人体姿态信息,而是直接从图像本身的纹理和结构特征出发,通过图模型和图像特征的结合来提高分割的精度。在传统的基于图像的分割方法中,图模型是一种常用的技术,它将图像分割问题转化为图的节点划分问题。李健书等人通过改进图模型,使得模型能够更好地捕捉服装的纹理和结构信息。这包括使用更精细的图表示方法,以及设计更有效的图划分算法。

除了图模型之外,李健书等人还强调了图像特征在服装解析中的重要性。他们提出使用深度学习技术来提取图像的局部和全局特征,包括颜色、纹理、形状等。这些特征能够帮助模型更好地理解服装的复杂纹理,并提高分割的准确性。

为了进一步提高分割的精度,李健书等人训练了一个成对的条件随机场(CRF)模型。CRF 是一种概率图模型,能够考虑像素之间的依赖关系,并利用上下文信息来优化分割结果。成对的 CRF 模型特别适用于服装解析任务,因为它可以同时处理前景(服装)和背景(非服装)的像素标签,从而避免了过分割和不准确估计的问题。

通过上述改进,李健书等人的方法在像素精度上取得了显著的提升,达到了 82.69%。这表明他们的方法在处理复杂纹理服装时具有较高的准确性和可靠性。

尽管李健书等人的方法在服装解析方面取得了显著的进步,但仍面临着一些挑战。特别是对于与肤色类似和不规则复杂纹理的服装,解析效果仍然不理想。这可能是因为这些服装的纹理与人体皮肤的颜色和纹理相似,导致模型难以区分服装和人体。此外,不规则的纹理可能缺乏明显的结构信息,使得传统的图像特征提取方法难以有效工作。

3.2.3 一种融合颜色与纹理特征的无监督分割算法

针对复杂场景下拍摄的服装图像分割问题,郭鑫鹏提出了一种基于先验知识的融合颜色和纹理特征的无监督分割算法。算法首先利用块截断编码思想将传统三维颜色空间截断为六维空间,得到更精细的颜色特征,并结合改进的局部二值模式纹理特征实现图像特征描述。然后,根据目标区域和背景区域在图像中的统计规律,提出了一种基于先验知识的两分法进行图像分割。实验表明,该算法能快速有效地将目标区域从不同复杂场景中分割出来,且不需要人工设定任何参数。主要研究内容如下:

(1) 颜色特征提取: 使用块截断编码(BTC)将 RGB 颜色模型转换为均匀的、适合聚类的 Lab 颜色模型, 并获取六维颜色特征。

假定有一个 $M \times N$ 的图像块, 其第 i 行第 j 列处的像素点 \mathbf{X}_{ij} 可以看作是一个包含 L, a, b 三个分量的特征向量, 这三个分量可以分别表示为 $\mathbf{X}_{ij}(L), \mathbf{X}_{ij}(a)$ 和 $\mathbf{X}_{ij}(b)$ 。计算该图像块颜色特征的算法步骤如下:

① 计算图像块的 L, a, b 三个分量的均值以及标准差, 记为 $\bar{L}, \bar{a}, \bar{b}$, 以及 $\sigma_L, \sigma_a, \sigma_b$, 其中 \bar{L} 和 σ_L 的值如下:

$$\bar{L} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N X_{ij}(L) \quad (3.2)$$

$$\sigma_L = \frac{1}{M \times N} \sqrt{\sum_{i=1}^M \sum_{j=1}^N (X_{ij}(L) - \bar{L})^2} \quad (3.3)$$

同理计算 \bar{a} 和 \bar{b} 以及 σ_a, σ_b 。

② 对图像块的 L, a, b 三个分量做截断处理, 现以 L 分量为例。将 \bar{L} 看作阈值, 与图像块中所有像素点的 L 值进行比较, 小于阈值的设定为 L_{low} , 反之设置为 L_{high} 。

$$L_{\text{low}} = \bar{L} - \sigma_L \sqrt{\frac{P}{M \times N - P}} \quad (3.4)$$

$$L_{\text{high}} = \bar{L} + \sigma_L \sqrt{\frac{M \times N - P}{P}} \quad (3.5)$$

③ 对图像块中所有像素的 a 和 b 分量也做上述的截断处理, 从而得到图像块的六维颜色特征 $L_{\text{low}}, L_{\text{high}}, a_{\text{low}}, a_{\text{high}}, b_{\text{low}}$ 和 b_{high} 。

(2) 纹理特征提取: 通过优化局部二值模式(LBP)算法, 在不影响图像纹理轮廓的前提下, 提取 16 维纹理特征, 降低特征维度同时保留纹理轮廓, 如图 3.4 所示。



图 3.4 LBP 提取特征前后图
(a) 原始的 LBP 特征图; (b) 改进后的 LBP 特征图

(3) 图像分割: 基于先验知识, 提出两分法对图像块进行聚类, 划分为目标区域和背景区域, 避免 K-means 算法的局部最优问题。

如图 3.5 所示, 若将每个图像分成 10×10 的网格, 根据先验知识, 图中粗线标记的 8 个图像块属于背景区域的概率非常大。假定一幅图像 S 包含 N 个子图像块, 即 $S = \{s_1, s_2, \dots, s_N\}$, 每一个子图像块 s_i 经过上述特征提取后可以看作一个 22 维的特征向量。这些子图像块分属于目标区域 G_1 和背景区域 G_2 这两个类别。初始情况下, 图中所标记的 8 个子图像块属于 G_2 , 即 $G_2 = \{s_1, s_2, \dots, s_8\}$, 剩余所有子图像块皆属于 G_1 , 即 $G_1 = \{s_9, s_{10}, \dots, s_N\}$ 。接下来需要将 G_1 中原本属于 G_2 的子图像块逐一挑选出来放入 G_2 , 最终得到的 G_1 中所有子图像块所组成的最大连通域即目标区域。算



图 3.5 划分示例图

法的具体步骤如下：

① 在 G_1 中挑选图像块放入 G_2 的过程应该遵守分类最优的原则,即定义目标函数:

$$E = \frac{1}{n_1 n_2} \sum_{i \in G_1, j \in G_2} \|s_i - s_j\| \quad (3.6)$$

其中, n_1 和 n_2 表示 G_1 和 G_2 中的图像块个数。目标函数表示 G_1 与 G_2 两类之间的类平均距离,其值越大,表明分类效果越好。

② 对 G_1 中的所有图像块做穷举,即分别计算把 s_9, s_{10}, \dots, s_N 并入 G_2 类时的目标函数,若当 s_i 并入 G_2 类时的目标函数值最大,则将 s_i 从 G_1 中取出放入 G_2 ,记录下此时目标函数为 $E(1)$,表示这是第一次做选取得到的目标函数。此时 $G_1 = \{s_j | j \neq i, \text{且 } 9 \leq j \leq N\}$, $G_2 = \{s_1, s_2, \dots, s_8, s_i\}$ 。

③ 重复步骤②,得到最大的目标函数为 $E(2)$,对应图像块记为 s_p 。比较目标函数 $E(1)$ 与 $E(2)$ 。若 $E(2) \geq E(1)$,则将 s_p 并入到 G_2 中,并继续重复上述步骤,直到当前的目标函数 $E(k+1)$ 小于前一次得到的目标函数 $E(k)$,则分类结束,以第 k 次得到的分类结果作为最终的分类结果。

④ 此时, G_1 中包含 $N-8-k$ 个子图像块, G_2 中包含 $8+k$ 个子图像块。将 G_1 中包含的子图像块所构成的最大连通域作为最终的目标区域,图像分割过程结束。

该算法由于不需要人工设定参数,它可以自适应地处理不同场景和条件下的服装图像,具有很好的通用性和灵活性。同时,通过融合颜色和纹理特征,该算法能够更准确地识别和分割服装的主要部分,即使在复杂背景中也能保持良好的分割效果。

尽管该算法在分割效果上取得了一定的成功,但特征维数并不高,这可能会限制算法的性能。高维特征可以提供更丰富的信息,有助于提高分割的准确性和鲁棒性。然而,高维特征也会带来计算复杂度高和过拟合的风险。

3.2.4 基于 HOG 和 E-SVM 的服装图像联合分割算法

针对服装图像分割准确率低的问题,黄冬艳等提出了基于 HOG(方向梯度直方图)和实例支持向量机(E-SVM)的服装图像联合分割算法。该算法的核心思想是利用 HOG 特征描述符捕捉图像中的局部纹理信息,并结合 E-SVM 进行有效的图像分割。这种方法不依赖于人体姿态信息,而是直接对服装图像进行分析和处理,从而实现分割。

如图 3.6 所示,(1)中的图像为辅助数据集中的图像,(2)为(1)中图像的服装区域的 HOG 特征图,(3)为输入图像。利用滑动窗口方法可以找出辅助数据集中服装图像的 HOG 与输入图像的 HOG 相似的区域,从而将该区域内的超像素进行组合,最终将输入图像中的服装分割出来。

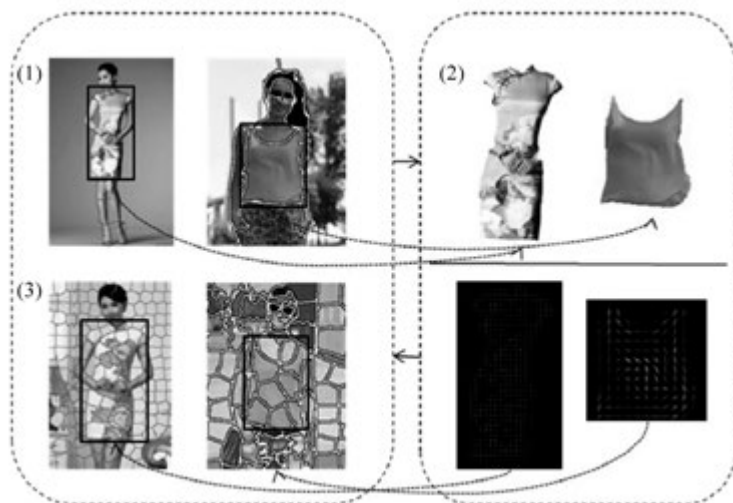


图 3.6 分割提取特征

(1) 辅助数据集; (2) 服装 HOG 特征图; (3) 输入图像

联合分割算法具体如下:

(1) HOG 特征: 方向梯度直方图 HOG 是一种在计算机视觉和图像处理中用来进行物体检测的特征描述子,通过计算并统计图像局部区域的梯度方向直方图来构成特征。HOG 描述子保持了几何和光学转化不变性。其核心思想是: 梯度或边缘的方向密度分布能够很好地描述图像中的局部区域的信息。首先,将图像分成若干个小的连通区域(图像细胞单元)。然后,统计每个图像细胞单元的梯度方向直方图。最后,将这些梯度方向直方图按照空间顺序组合起来以保存空间信息。为了保证光照不变性,算法对这些局部直方图在图像的更大范围内进行对比度归一化。

(2) 概率模型: 将联合分割视为一个概率模型,并利用辅助数据集 $g = \{g_1, g_2, \dots, g_n\}$ 来分割待检图像。结合用户输入的待检图像 G' , 定义参与分割的图像集合 $M = \{G', g\}$ 。概率函数 P 可定义为

$$P \propto \prod_{i=1}^{n+1} P(R_i | Y_i, M_i) P(W_i | R_i) \times P(Y_i | W_i, M_i) \quad (3.7)$$

式中, R 为区域变量。将集合 $M = \{G', g\}$ 进行超像素分割,由此单个图像可被表示成 $\{r\}_{ij}^j = 1$, 图像集合 M 则可表示成 $R = \{R_i = \{r_{ij}\}\}$, 且 $i = n+1$ 。

W 表示 E-SVM 权重。选择分割效果理想的区域用来训练 E-SVM 分类器,从而得到 E-SVM 权重 w_j 。由此可用变量 $W = \{W_i = \{w_{ij}\}\}$ 表示图像 G' 及辅助数据集 $g = \{g_1, g_2, \dots, g_n\}$ 的 E-SVM 权重。

Y 表示分割传播, $Y = (x, y, z)$ 。其中, (x, y) 表示位置信息, z 表示 E-SVM 分类器的

分割模板。 Y 表明分割模板 z 可以传播到图像的 (x, y) 位置处。利用滑动窗口方法选择出可能的分割传播。最后通过求解概率函数 P 的最大值来优化这三个变量。

(3) 联合分割算法：联合分割算法具体分为三个迭代的步骤,包括超像素组合、E-SVM 分类器训练、分割传播。首先将图像集合 M 进行超像素分割,并利用分割传播方法将超像素组合成多个区域 r_j 。选择分割效果积极的小区域,利用这些区域的 HOG 信息训练 E-SVM 检测器。再利用这些 E-SVM 检测器将待检图像 G' 和辅助数据集 g 中的服装分割出来,如图 3.7 所示。

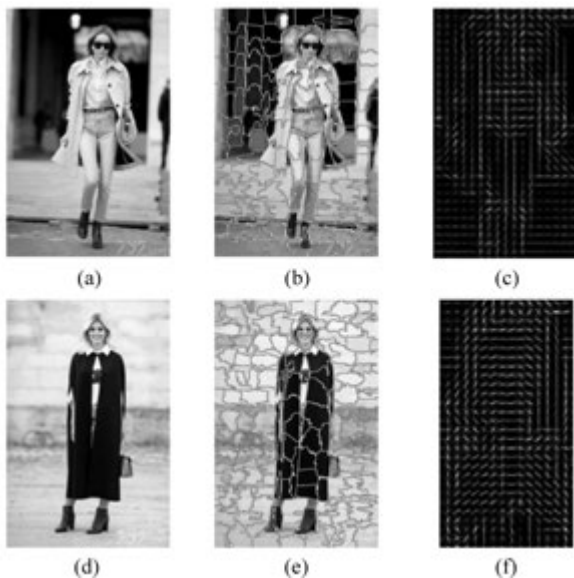


图 3.7 提取特征过程

(a) 原图 1; (b) 超像素分割 1; (c) HOG 特征 1; (d) 原图 2; (e) 超像素分割 2; (f) HOG 特征 2

尽管该算法在处理复杂纹理的服装图像方面表现出色,但它在以下方面仍面临挑战:

(1) 款式或样式繁多: 当服装的款式或样式非常多样化时,算法可能难以区分不同服装之间的细微差别,导致分割效果不佳。

(2) 颜色和背景相似: 如果服装的颜色与背景相似,HOG 特征可能不足以有效区分服装和背景,从而影响分割的准确性。

(3) 特征维数: HOG 特征的维数可能不足以捕捉所有必要的信息,特别是在服装和背景高度相似的情况下,这可能导致分割性能下降。

3.2.5 基于 Deeplab 网络的模型服装解析

白美丽提出的基于 Deeplab 网络的模型是一种先进的深度学习方法,旨在解决服装解析问题。这种方法利用当前流行的深度分割模型,从像素级别上捕捉服装的高层次语义信息,并考虑服装类别之间的上下文联系信息。

Deeplabv2 是一种流行的深度学习分割模型,它使用空洞卷积(atrous convolution)来扩大感受野,同时保持分辨率不变。这使得模型能够在不降低图像分辨率的情况下,捕捉到更广泛的上下文信息。

该预训练模型是在大型数据集(如 ImageNet)上训练得到的,它已经学习到了丰富的视觉特征。通过使用 Deeplabv2 的预训练模型作为起点,可以加速训练过程并提高模型的泛化能力。其所使用的 LIP(large-scale image parsing)数据集是一个用于图像解析的大型数据集,包含了丰富的类别和实例。使用这个数据集来训练模型,可以帮助模型学习到更细致的服装类别和结构信息。

该模型自监督学习策略通过引入结构性敏感损失,使模型在训练过程中更加关注人体关节的结构信息。这种损失函数可以帮助模型更好地理解人体的姿态和服装的布局。在预训练的基础上,该模型使用自监督学习策略对模型进行微调。这一过程通过调整模型的参数,使其更好地适应特定的服装解析任务。

该模型将经过自监督学习策略微调后的模型参数作为目标任务数据集的初始化参数。这可以为模型提供一个良好的起点,加速目标任务的学习过程。该模型在目标任务数据集上进行二次训练,使用随机梯度下降等优化算法来进一步调整模型参数。这一过程使模型能够更准确地识别和分割目标任务中的服装图像。

Deeplab 网络能够从像素级别捕捉服装的高层次语义信息,提高了服装解析的准确性。通过考虑服装类别之间的上下文联系,该模型能够更好地理解服装在图像中的关系和布局。同时,自监督学习策略的引入使得该模型能够更好地理解人体结构,从而提高服装解析的性能。Deeplabv2 的算法流程如图 3.8 所示。

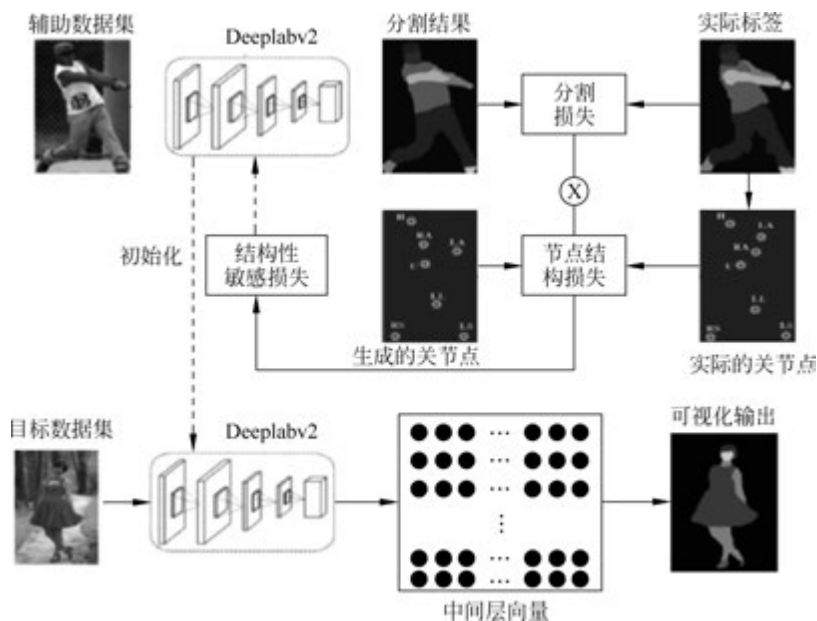


图 3.8 Deeplabv2-SSL 算法流程图

尽管该模型在服装解析方面取得了一定的成功,但仍可能面临一些挑战,如处理不同光照条件下的图像、处理高度相似的服装类别等。

3.2.6 自监督结构敏感学习的分析方法

自监督结构敏感学习(SSL)是一种先进的分析方法,它在服装解析任务中引入了结构