

指导教师： 杨涛

提交时间： 2016/3/20

# CVPR2015 Paper Translation

No: 01

姓名： 赵迪

学号： 2013302564



班号： 100110304

# 人脸识别的深度学习三大特征：稀疏性，有选择性，健壮性

Yi Sun

Xiaogang Wang

Xiaou Tang

## 摘要

本文设计了一种高效的深度卷积网络人脸识别方法（deepid2+）。使用分类的监督学习，通过增加隐含的表达方式和增加监督卷积层的尺寸，deepid2+在国家最先进的LFW上达到新的高度并且通过了YouTube脸部识别基准。

通过观察研究，我们发现深层神经激活的高性能的三个关键：稀疏性、选择性和健壮性。（1）使神经适度稀疏，适度稀疏最大限度地提高深网的辨别力以及图像之间的距离。令人惊奇的是DeepID2+仍然可以实现神经反应进行二值化，可以达到高识别准确度。（2）更高层的神经元是高度选择性的身份和身份相关的属性。我们可以找出哪些神经元是不断的兴奋，不同的身份和属性都存在抑制的不同子集。虽然DeepID2+不训练中来区分属性，但它含蓄地了解到这种高

层次的概念。（3）可以达到更健壮性，虽然遮挡图案并不在训练集内。

## 1. 引入

人脸识别取得了巨大的进步得益于人们致力于这一领域的研究工作。在追求更高的性能是一个不变的话题，但了解背后的机制也是同样重要。当神经网络开始有人挑战的脸部识别的基准，人们都渴望知道这些神经元是怎么被训练的，怎么实现这么的高性能。在认知科学，有很多对视皮

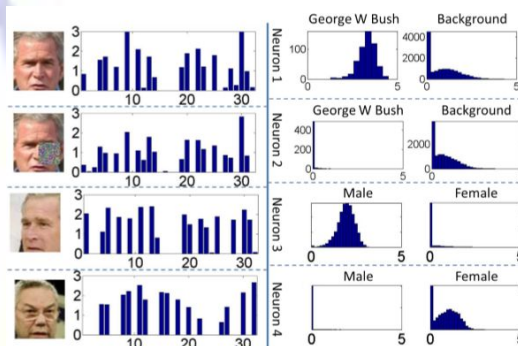


图 1：左侧：对 deepid2+ 对布什和鲍威尔图像的神经反应。面部部分遮挡。右侧：在对男女图识别，神经元选择显示激活直方图：分别为布什脸部，男

性脸部，女性脸部，表明神经元的稀疏性，选择身份和特征。

层神经元进行分析面对处理机制研究。受到这些作品的启发，我们分析了布什和鲍威尔的可识别遮挡，具有

有 512 元的具有顶部隐层的 DeepID2+ 模型。我们二次采样的 32 个例子作说明。右图：几个神经元被训练判别在 LFW 的人脸图像，图表显示其激活直方图，分别是布什的不同图像，男性的不同图像，女性的不同图像。一个神经元一般是激活了约一半的人脸图像。但它可能不断地对所有属于一个特定的人或属性图像激活（或不激活）。在这个意义上说，神经元是稀疏的，来选择图像人脸的身份和属性。

下面了解在深度面部识别过程中的人工神经网络神经元的行为，以及什么样的信息被编码在神经元，还有他们变强大和衰败的过程。

我们的研究是基于一个高性能的深度卷积神经网络简称 deepid2+，提出的方法，这是改进国家的最先进的 deepid2 通过增加隐含表达的维数和增加监督卷积层。最好的单 deepid2+ 模型（以原始和水平翻转的人脸图像作为输入）验证精度达到 98.70%

结合 25 个 deepid2+ 网络节点新的方法在多个基准取得良好成绩：在 LFW 人脸成绩 99.47%（deepid2 方法文章 [23] 成绩 99.15%），在 LFW 上封闭和开放人脸识别分别为 95% 和 80.7%，（82.5% 和 61.9%（WST 方法）文章 [28]），在 youtube 人脸识别 93.2%

（深度人脸识别文 [27] 91.4%）。

我们调查了三个对于神经元激活高性能的特性：稀疏性，选择性，和鲁棒性。神经元 deepid2+ 在面对大数据量的训练后，我们没有使用任何额外的正则化模型和训练过程。因此，以下结果对了解深度网络的内在属性具有极大的价值。

deepid2+ 神经激活适度稀疏：如图 1 所示，对于输入人脸图像，在顶部隐藏层中的神经元一半左右被激活。另一方面，每一个神经元被激活的人脸图像大约一半。这样的稀疏分布，可以最大限度地提高深网的辨别力，以及图像区分距离。不同的身份不同的神经元的子集激活。相同身份的图像具有相似的激活。这促使我们神经反应激活在顶部的隐藏层，若使用二进制方式进行识别，结果是出乎意料的好，其鉴别精度在 LFW 上仅略下降 1% 甚至更少。这个结果具有显著的影响，因为巨大的存储和计算时间限制大规模的人脸搜索。这也意味着，二进制的激活方式比深层神经网络的激活更有价值。

关于稀疏，还观察到在较高的层的神经元在身份和身份的高度上选择的相关属性。当一张脸部图片（任何外部的训练数据）或属性，我们可以判别为神经元的一个子集，使神经元不断兴奋，也可以找到另一个神经元的子集，不断产生抑制。任意两个子集的神经元都有很强的指示，表明存在或不存在这个身份或属性，我们的实



验表明，单神经元对于一个特定的身份或属性具有较高的识别精度的。换句话说，神经的激活对身份和属性的稀疏性，如图 1 所示的例子。虽然 deepid2+不区分属性训练，但它含蓄地学会高层次的分类概念。直接利用人脸的 deepid2+学习可以大搞更高的分类精度，对身份相关的属性比广泛使用的人工制作的功能，如高维 LBP [6]要好的多。

我们的实践研究表明，在更高层次的神经元拥有更强大的人脸识别图像能力，而在较低层的高维 LBP 或神经元，如图 1 所示，当人脸图像被部分遮挡时，其二进制激活模式保持稳定，虽然大小可能不一样。我们推测的原因可能是，在更高层次的神经元捕捉到全局特征，对于局部变化不是非常敏感。我们的 deepid2+使用网络人脸图像和无认为遮挡方式的图片训练。

## 2. 最新进展

在最新研究中，深度学习实现人脸识别[27, 25, 23]

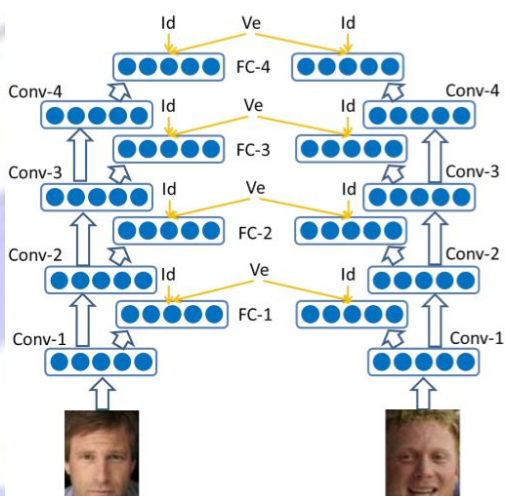


图 2: deepid2+网络、监控信号蓝色箭头表示正向

传播。黄色箭头指示监视信号。在左、右网不同输入相同的 deepid2+网面。

outper 系统的巨大的成功是使用低级别的功能[2, 22, 6,4]达到了巨大的成就。有两个显著的突破，第一个是大规模应用了脸部识别深层神经网络[27, 25]。通过人脸图像分类为数千甚至数百万的分类，最后以隐层形式的方式高度分类身份，性别。二是监督深度神经网络的既可以进行脸部识别和验证工作[23]。验证任务是最小化相同的身份的特征之间的距离，并降低个人的变化的影响[23]。通过结合多种选择的人脸区域的特征

了解到， [23]所取得的 LFW 成绩 (99.15%)是最先进的人脸验证方法。

属性学习是一个热门的话题[9, 21, 20, 36]。在第一次学习了属性分类和人脸识别使用属性已经有作品 [14] [7]。我们在本文中尝试相反的方向，由第一预测的身份，然后使用了解到身份 - 相关的特性来预测的属性。

基于稀疏分类[33, 34, 35, 8]被广泛研究的人脸识别。 Tang 等人[29]建议稳健玻尔兹曼机来区分损坏像素和提升潜在的学习表现。这些方法设计的部件明确地处理图像遮挡，而我们在 DeepID2+中已经了解到隐式编码不变性来处理遮挡。这是不增加调节图像或认为遮挡图像的训练数据下实现。

逐层训练的神经网络，由 LEE 等人提出和分析[17]。我们 DeepID2+网

进行类似的监督方式，但对于不同的网络结构和监控信号。使用 ConvNet 特征进行二进位化，研究发现，在保持在物体识别[1]的性能情况下，我们的方法更注重面部识别并具备稀疏属性。

### 3. DeepID2+ 网络

deepid2 + 继承 deepid2 [23] 的四层卷积特性，其次是最大面积区域，使用  $55 \times 47$  的输入尺寸和  $47 \times 47$  的方形脸识别区域。deepid2 + 相对 deepid2 三处改进如下：首先，deepid2 + 在每层卷积上使用 128 个特征映射，特征表示也增加到 512 个维度。其次，




图 3: DeepID2 与 DeepID2+ 对比

我们的训练数据是通过合并 celebfaces 上的数据集[25]和放大的 wdref 数据集[5]，和一些新收集的 LFW 数据。我们的 deepid2 + 大约有 290000 的人脸图像和 12000 个不同身份相比之下 deepid2 使用了 160000 图像和 8000 个不同身份训练。第三，我们加强监督的 512 维全连接层连接的四个卷积层，简记为 fc-n  $n=1, 2, 3, 4$ ，监督这四个全连接层与进行身份验证监控信号[23]，如图 2 所示。

### 4. 高性能的 DeepID2+ 网络

为了识别验证身份改进，我们训练 25 个 deepid2 + 网络以对应 25 个人脸区域的 deepid2 [23]，在 LFW 人脸验证任务[13]试验进行测试。由于在 deepid2 + FC-4 层特点，所以使用基于贝叶斯联合方法[5]的训练，我们的培训 2000 人组（独家从 LFW 获取）的人脸进行验证。25 个 ConvNets 的比较如图 3 所示（在原有的或水平翻转人脸区域，如图 2 所示，在[23]中提取）。deepid2 + 比 deepid2 提高约 2% 的人脸验证精度。

当结合 FC-4 层特征从 25 个区域及其水平翻转的 deepid2 +，我们分别在 LFW 和 YouTube 的数据集实现 99.47% 和 93.2% 的人脸验证精度。图 4 和图 5 是 ROC 上的数据集比较。我们的 deepid2 + 网超越以前所有的结果。在 deepid2 + 测试 LFW 和 youtube 脸部识别的时候有几处错误标记有。修正后，我们的人脸验证的精度提高到 99.52%（youtube）和 93.8%（LFW）。

人脸识别在高可靠性人脸识别系统中更加具挑战性[28]。因此，我们进一步探讨 25 deepid2 + 网在封闭和开放人脸识别任务上，在[3]的准则上，闭集识别报告排名识别精度和开集识别报告的检测和识别率（DIR）只有 1% 的误报率（FAR）。对比结果显示在标签 3。我们的研究结果显著优于以前最好[28]与 95% 和 80.7% 的封闭和开放的设置识别精度。

### 5. 激活神经元的稀疏性

神经的激活是在两种意义上的适度稀疏，对于每个图像，在被激活的神经元（具有正激活值）的大约有一半，并且对于每个神经元，大约有在激活图像的一半。在图像上适度的稀疏性，使不同身份的面孔得到最大区分，而神经元的适度稀疏，使他们有最大的分辨能力。我们通过计算每个

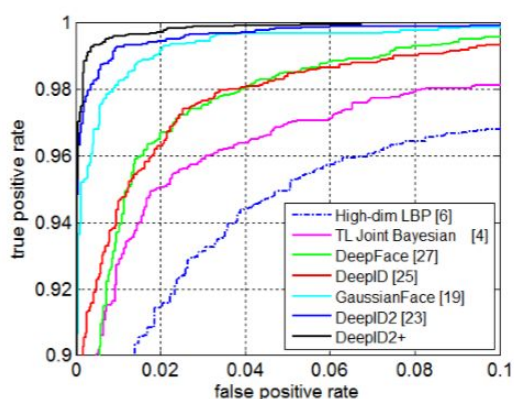


图 4: ROC 在 LFW 上脸部识别结果

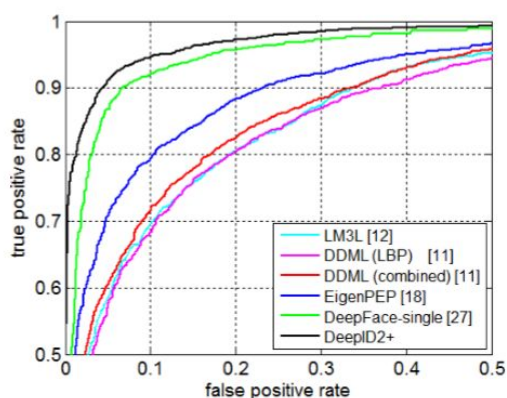


图 5: ROC 在 YouTube 脸部识别结果

在我们的验证数据集中的 46,594 个图像的激活神经数的直方图验证此（图 6 左侧），并在其上每个神经元被激活（图 6 右）。评价是基于在一个单一的 Deepid2 对 FC-4 层的神经元将整个脸部区域作为输入。相比之下，在 FC-4 层的所有 512 个神经元，在图像上激活的神经元的数量的平均值和标准偏差是  $292 \pm 34$ ，而相对于所

有 46594 验证图像的平均值和图像的数量标准偏差在其上每个神经元为  $26,565 \pm 5754$ ，这两者都是近似的所有神经元/图像的一半为中心而扩展。我们的实验也表明，该稀疏水平不受丢包率[10]的影响。我们训练期间 FC-n 层有神经元丢失。适度稀疏属性有不同的丢失率以及丢失不学习。50%的丢失率被选择用于 DeepID2+。




图 6 左: 每个验证图像的激活神经元的数量的直方图。右边: 每个神经元被激活的图像的直方图。

我们进一步验证该激活模式，即神经元是否被激活，这比精确激活值更重要。我们把神经激活以二进制代码通过阈值，并比较它在 LFW 识别能力，二进制表示相比原来的表示（不使用二进制），牺牲 1% 或更少的精确度（97.67% 和具有单网 99.12%）。更有趣的是，即使是直接计算的汉明距离，二进制码仍然可以达到 96.45% 和 97.47% 的准确度与单个网或组合的 25 个网络相比。这表明，激发或神经元抑制的状态已经包含了大部分的区别信息。二进制代码是更具性价比在存储和快速的图像搜索方面。我们相信，这将是今后工作的一个有趣的方向。

## 6. 对身份和属性的选择

### 6.1. 神经元的辨识力



我们的测试针对两个二元分类的 DeepID2+。首先是对一个人的面部图像从所有其他人或背景进行分类。第二是面部图像有没有属性进行分类。实验与训练中的 DeepID2+ 在 LFW [13] 中进行。LFW 随机分成两个子集和交叉验证并生成精度报告。该精度是 w.r.t. 在正和负类的图像编号。我们也比较高维 LBP [6] 与各种特征的尺寸，如示于图 7，DeepID2+ 在属性分类跑赢了 LBP（这并不奇怪，DeepID2+ 具有良好的识别分类的结果）在图 8 和图 9 的身份和属性分类精度只有一个最大的特点分类。不同的最佳特征选择不同的身份（属性）。与单一功能（神经元）相比，DeepID2+ 成功分类某种身份或属性率约为 97%。这些证据表明 DeepID2+ 优秀的身份和属性判别。显然，LBP 没有它好。

### 6. 2. 兴奋和抑制的神经元

我们发现，特殊的身份和面部属性是由于神经元的兴奋和抑制模式的某些特性或属性。例如，一个神经元看见柯林鲍威尔兴奋，当它看到布什而抑制，或一个神经元看到西方人行文而看到亚洲人抑制。图 10a 分别是 deepid2+ 神经的激活在一个特定的单一身份的图像（左栏）和剩下的图像（中柱），以及从剩余的图像每区分每个身份神经元的分类精度（右列）的均值和标准差。在 LFW 人脸图像进行评估（见本文 [26] 完整版身份）。对于每一个给定的身份有强烈兴奋的神元（例如那些神经 ID 小于 200）

或抑制（例如神经 ID 大于 600），兴奋的神经元，激活具有更高的值，而其他的图像，这些神经元有明显较低的平均值。因此，兴奋性神经元可以很容易地辨别他人的身份。




图 7: Deepid2+和 LBP 属性分类对比




图 8: 对单一特征的属性分类比较




图 9: 属性分类精度对比

在中间（神经 ID 400 左右），在中间的神元，他们对给定的身份有较弱的辨别能力，在双色点附近的红色和蓝色点是低精度验证。这些神经元的兴奋或抑制状态有很大的不确定性。

当平均激活进一步降低（神经 ID 600 以上），神经元表现出抑制性能，并且很少激活给定的身份。这些抑制性神经元也具有较高的分类精度的分

类能力。

然而，类似的现象没有 LBP 特征中体现如图 10b 所示。LBP 特征在特定身份的激活分布和剩余的图像重叠的所有功能。相比 deepid2 + 神经激活，LBP 特征的分类准确率要低得多，其中大部分是在 50% 随机猜测线积累。同样的结论也适用于图 11a 和 11b 所示的属性图（见更多的例子，在完整版 [26] 中讨论）。

### 6.3. 神经激活分布

图 12 和图 13 是神经在给定的身份或属性激活的直方图显示的例子。图 10 还显示了 12 个随机选择的神经元对所有图像反应的直方图。对于一个神经元，当有一半的激活是零（或接近零），则另一半有较大的价值。




图 10 (a) Deepid2+ 神经元激活分布




图 10 (b) LBP 神经元激活分布

相反，在给定的身份表现出很强的选择性的直方图，一些神经元被不断激活的一个给定的身份，与激活直方图分布在正的值，如图 12 中的第一行的每一个身份的直方图。而其他一些被不断抑制，在直方图积累在零或小的

值，如图中的每一个身份的直方图。

在图 13a、13b，我们显示了一些与性别和种族相关的属性。神经元或是兴奋（在红色帧）或抑制（在绿色的帧）。这些数字表明，我们的的神经元和 LBP 特征的每个神经元的激活在 LFW 人脸图像拥有最佳的分类精度。左栏：神经的同一个身份图像激活均值和标准偏差。平均线用红线表示，标准偏差为代表的垂直段之间（平均-标准偏差）和（平均值±标准差）。神经元对平均激活给定的身份进行排序。中：神经对剩余图像激活均值和标准偏差。神经相同命令在左边的列。右栏：每一个神经元对给定身份的分类精度。相同的神经元命令在左边和中间的列。神经元对一个给定的身份激活和抑制的被分别标记为红色和蓝色的点。

关于神经元对于给定的属性表现出很强的选择性（激活或抑制），在本文的完整版本 [26] 我们展示了更多的身份和属性分布直方图。

## 7. DeepID2+ 的健壮特征

我们测试 deepid2 + 特征对人脸图像的健壮性。在第一个设置中，部分遮挡 10% 到 70% 的区域，如图 14 第一行所示。在二次设置中，人脸被随机分为 10~10、70、70、像素的随机块，如图 14 所示。在实验中，deepid2 + 联合贝叶斯模型对原始人脸图像在对没有任何人工添加遮挡的图像进行训






图11 (a) : deepid2 + 神经激活分布和每神经元分类精度




图11 (b) : LBP神经激活分布和每神经元分类精度

练，而遮挡的面孔只用于测试。我们还测试了高维LBP特征加上联合贝叶斯模型[ 6 ]作为比较。图15比较了 deepid2 + 和LBP对不同部分遮挡度在 LFW测试集[ 13 ] 人脸识别的精度比较。我们也评估整个人脸识别系统的25层 deepid2 + 网。高维LBP特征比是99，从21的面部特征提取的120个维度。如图15所示，即使是轻微的10% - 20%遮挡，LBP的表现急剧下降。




图 12: 神经激活直方图

相反，对于 deepid2 + 特征两个以上 (FC-2、FC-3和FC-4卷积)，在大范围内性能是缓慢的下降。deepid2 + 人脸识别的精度仍在90%以上，而对于40%的面孔遮挡，而LBP特征的性能已经降到70%以下。而当面孔有超过50%的遮挡时候 deepid2 + 的性能才迅速降低，其临界区域是遮挡眼睛。




图 13: 在激活神经属性直方。

结合 deepid2 + 从25面区域提取达到最健壮人脸验证精度93.9% (在40%遮挡下) 甚至可以在只显示前额和头发的情况下达到88.2%精度。



图 14: 部分脸遮挡测试.从 10%遮挡到 70%脸部遮挡

我们也评估人脸验证 deepid2 + 和 LBP 特征的人脸图像随机块遮挡， $N \times n = 10$  到 70 块的大小，这种设置是具有挑战性的，因为在 2 个遮挡区域的位置通常是不同的。因此，同一个人的图像在像素距离上看起来有很大的不同。图 16 显示比较结果，LBP 特征的准确率在块的大小是大于  $20 \times 20$  时开始迅速下降时，而 deepid2 + 维持在一个较大范围的高性能。当  $50 \times 50$  块遮挡，LBP 特征的性能已下降到约 70%，而一个单一的 deepid2

+FC-4 层仍具有 89.2%的准确率，要综合 25 个 deepid2+网具有更高的精度 92.4%。上述实验结果表明，它的深层结构，使神经元图像更强大。这种健壮性是内在的 ConvNets 并没有显式模型。




图 15: 面对部分遮挡的 deepid2+和高维的 LBP 精度测试




图 16: 面对随机部分遮挡的 deepid2+和高维的 LBP 精度测试

图 17 显示了 FC-4 层神经元在单一的有不同程度随机遮挡的身份图像的平均激活。对于这两种类型的遮挡，激活模式在很大程度上保持不变，直到一个很大程度的遮挡。在完整版中看到更多身份的例子[ 26 ]。




图 17: 平均神经激活在图 14 中布什图像和随机分组面部图像

## 8. 总结

本文设计了一种高性能的 deepid2+网络，在 LFW 和 YouTube 基准上进行脸部识别和验证的面孔。通过研究发现，deepid2+具有适度稀疏，身份和属性的高度选择性，和强大的图像抗遮挡能力。在前些时间，许多研究工作已经告一段落，旨在通过明确自己的模型或在系统中添加或调整以实现如此吸引人的特性。并且，人们也可以很自然地通过大规模的培训，通过深度模型实现本文的特性。这项工作不仅显著地提升人脸识别系统的性能，而且还提供了宝贵的见解，帮助人们深入理解学习现有的许多计算机视觉的研究如稀疏表示，属性的学习和对遮挡处理。

## 参考文献

- [1] P. Agrawal, R. Girshick, and J. Malik. Analyzing the performance of multilayer neural networks for object recognition. In Proc. ECCV, 2014.
- [2] T. Berg and P. Belhumeur. Tom-vs-Pete classifiers and identity-preserving alignment for face verification. In Proc. BMVC, 2012.
- [3] L. Best-Rowden, H. Han, C. Otto, B. Klare, and A. K. Jain. Unconstrained face recognition: Identifying a person of interest from a media collection. TR

MSU-CSE-14-1, 2014.

[4] X. Cao, D. Wipf, F. Wen, and G. Duan. A practical transfer learning algorithm for face verification. In Proc. ICCV, 2013.

[5] D. Chen, X. Cao, L. Wang, F. Wen, and J. Sun. Bayesian face revisited: A joint formulation. In Proc. ECCV, 2012.

[6] D. Chen, X. Cao, F. Wen, and J. Sun. Blessing of dimensionality: High-dimensional feature and its efficient compression for face verification. In Proc. CVPR, 2013.

[7] J. Chung, D. Lee, Y. Seo, and C. D. Yoo. Deep attribute networks. In Deep Learning and Unsupervised Feature Learning NIPS Workshop, 2012.

[8] E. Elhamifar and R. Vidal. Robust classification using structured sparse representation. In Proc. CVPR, 2011.

[9] A. Farhadi, I. Endres, D. Hoiem, and D. Forsyth. Describing objects by their attributes. In Proc. CVPR, 2009.

[10] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Improving neural networks by preventing co-adaptation of feature detectors. CoRR, abs/1207.0580, 2012.

[11] J. Hu, J. Lu, and Y.-P. Tan. Discriminative deep metric learning for face verification in the wild. In Proc. CVPR, 2014.

[12] J. Hu, J. Lu, J. Yuan, and Y.-P. Tan. Large margin multimetric learning for face and kinship verification in the wild. In Proc. ACCV, 2014.

[13] G. B. Huang, M. Ramesh, T. Berg, and E. LearnedMiller. Labeled Faces in the Wild: A database for studying face recognition in unconstrained environments. Technical Report 07-49, University of Massachusetts, Amherst, 2007.

[14] N. Kumar, A. C. Berg, P. N. Belhumeur, and S. K. Nayar. Attribute and simile classifiers for face verification. In Proc. ICCV, 2009.

[15] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel. Backpropagation applied to handwritten zip code recognition. Neural Comput., 1:541-551, 1989.

[16] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient based learning applied to document recognition. Proceedings of the IEEE, 1998.

[17] C.-Y. Lee, S. Xie, P. Gallagher, Z. Zhang, and Z. Tu. Deeply supervised nets. Technical report, arXiv:1409.5185, 2014.

[18] H. Li, G. Hua, X. Shen, Z. Lin, and J. Brandt. Eigen-pep for video face recognition. 2014.

[19] C. Lu and X. Tang. Surpassing human-level face verification



- performance on LFW with GaussianFace. In Proc. AAAI, 2015.
- [20] P. Luo, X. Wang, and X. Tang. A deep sum-product architecture for robust facial attributes analysis. In Proc. ICCV, 2013.
- [21] D. Parikh and K. Grauman. Relative attributes. In Proc. ICCV, 2011.
- [22] K. Simonyan, O. M. Parkhi, A. Vedaldi, and A. Zisserman. Fisher vector faces in the wild. In Proc. BMVC, 2013.
- [23] Y. Sun, Y. Chen, X. Wang, and X. Tang. Deep learning face representation by joint identification-verification. In Proc. NIPS, 2014.
- [24] Y. Sun, X. Wang, and X. Tang. Hybrid deep learning for face verification. In Proc. ICCV, 2013.
- [25] Y. Sun, X. Wang, and X. Tang. Deep learning face representation from predicting 10,000 classes. In Proc. CVPR, 2014.
- [26] Y. Sun, X. Wang, and X. Tang. Deeply learned face representations are sparse, selective, and robust. Technical report, arXiv:1412.1265, 2014.
- [27] Y. Taigman, M. Yang, M. Ranzato, and L. Wolf. DeepFace: Closing the gap to human-level performance in face verification. In Proc. CVPR, 2014.
- [28] Y. Taigman, M. Yang, M. Ranzato, and L. Wolf. Webscale training for face identification. Technical report, arXiv:1406.5266, 2014.
- [29] Y. Tang, R. Salakhutdinov, and G. Hinton. Robust boltzmann machines for recognition and denoising. In Proc. CVPR, 2012.
- [30] D. Y. Tsao and M. S. Livingstone. Neural mechanisms for face perception. *Annu Rev Neurosci*, 31:411–438, 2008.
- [31] X. Wang and X. Tang. A unified framework for subspace face recognition. *PAMI*, 26:1222–1228, 2004.
- [32] L. Wolf, T. Hassner, and I. Maoz. Face recognition in unconstrained videos with matched background similarity. In Proc. CVPR, 2011.
- [33] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma. Robust face recognition via sparse representation. *PAMI*, 31:210–227, 2009.
- [34] M. Yang and L. Zhang. Gabor feature based sparse representation for face recognition with gabor occlusion dictionary. In Proc. ECCV, 2010.
- [35] L. Zhang, M. Yang, and X. Feng. Sparse representation or collaborative representation: Which helps face recognition? In Proc. ICCV, 2011.
- [36] N. Zhang, M. Paluri, M. Ranzato, T. Darrell, and L. Bourdev. PANDA: Pose aligned networks for deep attribute modeling. In Proc. CVPR, 2014.
- [37] Z. Zhu, P. Luo, X. Wang, and X.

Tang. Deep learning identity-preserving face space. In Proc. ICCV, 2013.

[38] Z. Zhu, P. Luo, X. Wang, and X. Tang. Deep learning and disentangling face representation by multi-view perceptron. In Proc. NIPS, 2014.

