

指导教师： 杨涛 提交时间： 2015/3/29

The task of
Digital Image Processing

数字图像处理

School of Computer Science

No: 1

姓名： 魏紫薇

学号： 2012302551

班号： 10011207



物体和场景的即时识别

Sergey Karayev

Mario Fritz

Trevor Darrell

UC Berkeley

Max Planck Institute for Informatics

UC Berkeley

摘要

人类扫视即可感知一个场景，并且能在额外的时间段获知更深层次的理解。同样地，视觉识别部署应该强大到进行不同的计算预算。这些情况要求任何时候都有在计算机视觉研究领域很少考虑到的识别能力。我们提供一种学习动态策略的方法来优化在视觉体系的时间性能。我们的模型有序地进行特征计算并随后执行分类。最重要的是，在测试的时候作出决定，它取决于观察的数据和中间结果。我们展示这个系统对场景中的标准问题和物体识别的适用性。在合适的数据集上，我们能组成一个语义回退策略，它给予最大限度的所需精度的具体的预测；这提供了一个人类视觉时间方面的新视野。

1. 介绍

时间识别是人类感官的核心竞争

力，其在反射识别和视觉输入的深度分析中起调解作用。当更多时间可用时，人类研究提供了由粗到细处理视觉输入的依据[11, 19]。因为解释时间的动态的尝试很少，所以潜在的机制是不可知的（例子取自时序决定过程[15]）。

当在计算机视觉中不同等级的识别达到了允许有用的真实世界应用的性能水平时，最先进的方法往往计算昂贵且对时间任意性不敏感。当这些方法大范围使用时，管理它们的资源消耗（电源和 CPU 时间）变得尤为重要。例如个人机器人技术任务，部署不同的对刺激处理水平的能力同样是至关重要的，且取决于对机器人计算的要求。对于大多数最先进的分类方法而言，不同的特征提取自不同花销的图像实例，且对减少分类错误贡献不同。虽然“特征越多越好”，但是在一些例子中仅仅一小部分特征就能达

到高精度-而且不同的例子受益于特征的不同部分。例如，简单的二进制特征能很快人脸检测[22]但不区别视觉对象，就像对分离室内场景中的景象最有用的特征[24]和对识别鸟的物种之间的区别最有用的特征不同[10]。

因为每个特征带来了显著的计算负担，所以在对一个对时间任意性需要敏感的部署里计算所有图像的所有特征是不可行。为了解决这个问题，我们可以制定一个明确的成本预算，指定墙时间或总电力消耗或另一种度量。此外，我们争取时间任意性-在成本预算被耗尽之前终止分类器并且仍能获得最佳答案的能力。在这篇论文中，我们处理在时间任意成本预算下的选择和组合特征的一部分的问题。

为了利用不同例子受益于不同部分的特征的事实，我们的特征选择方法是一个顺序的策略。为了得到策略参数，我们制定了问题作为马尔可夫决策过程(MDP)并使用强化学习方法。通过不同的参数设置，我们能得到不同的策略，从不依赖于任何观察到的特征值的**静态的**，**近视的**贪心选择，到**动态的**，**非近视的**，依赖于观察值并考虑未来的动作。

由于我们的动机是测试时间效率，

我们的方法应该带来很小的计算负担，出于这个原因，我们的模型是基于线性评价而不是近邻或图形模型方法。因为不同的例子可选不同特征，而且我们的系统可能在运行时的任意时刻被调用去计算答案，所以特征结合方法对于大量不同观察特征应该是强大的。为了这个目的，我们提出一个新的可以学习不同观察特征集群分类器的方法。

我们在不同等级的识别任务上评价我们的方法。我们首先论证我们的算法得到的对具体测试实例最有用的特征的综合数据，我们论证超越贪心算法的非近视和超越静态的动态的优点和场景—15 可视化分类数据集。然后我们展示了分层的 ImageNet 数据集的子集上的结果，关于我们提供的关于期望的成本预算和精度的最精确的答案。

2. 相关的工作

静态选择 众所周知的评价特征的方法是 Viola & Jones[22]的促进级联的分类器（被 Bourdev & Brandt[2]用软阈值更新），这个方法可以在例子的所有特征被计算前退出评价，但是没考虑特征成本。Chen 等人[3]的成本敏感栅优化了级阶和阈值来共同减少分类

错误和特征计算成本。Xu 等人[26]和 Grubb & Bagnell [13]单独开发了训练成本敏感的分类器的梯形推进的变型；后者证明了他们的子模结果的贪心算法的最优性。他们的方法与阶段性的回归算法紧耦合。

动态选择 前面的方法得到了一个有效的和混合的评价测试实例中给定的特征的规则。Gao & Koller [12]提出了一个有效的分类方法：根据已选择的特征得到期望的信息然后目光短浅地选择下一个特征。这个方法基于局部加权的回归算法，测试时间成本很高。Ji & Carin [16]也制定了一个作为 HMM 条件下的动作的成本敏感的特征选择算法的变型，但是选择动作时目光短浅，造成测试时间成本高。

Karayev 等人[17]提出了选择目标探测器的强化学习方法；在一个图形模型中他们依赖于昂贵的测试时间推理去组合观察结果。Dulac-Arnold 等人提出了另一个基于 MDP 的“数据明智的分类”的解决方案，它有一个包括所有特征和标志的动作空间，最近被拓展到基于区域的过程[9]的领域。He He 等人[14]也制定了一个 MDP，用特征和一个单一的分类步骤作为动作，但是通过对贪心策略的模仿学习解决了它。Benbouzid 等人[1]制作了一个

MDP，它用额外的跳跃动作扩展了传统的顺序推进分类器，大大限制了学习策略的空间（[21]提供了这个问题的另一个变型）。虽然[17]得到目标即时性能，但是它们的推理过程在一个通用分类任务上对于测试时间的消耗很大。相反，我们的快速线性算法直接确定了即时成本预算。

标签树通过一个分类器树指导实例；混淆矩阵和加权共同学习决定了它们的结构[7]。Xu 等人[25]通过初级学者的类似于[3]的循环优化的方法学习了成本敏感二进制树。不直接相关但是令人激动的是[23]的工作的新奇，它对结构模型进行了简单的改进，使人类的姿态估计达到显著的加速。另一个激动人心的方向是人类环[4]的最优接近策略的理论分析。




图 1: 奖励功能的定义。为了熵和成本曲线从 0 到 B 的总面积的最大化，我们定义一个单一动作作为为总面积有贡献的面积片。从状态 s ，动作 a 得到

状态 s' 和成本 c_f 。获得的信息是

$$I_{H_s}(Y; h_f) = H(Y; H_s) - H(Y; H_s \cup h_f)。$$

3. 成本敏感的动态特征选择的即时分类

定义 1. 测试时间有效的多等级分类问题的组成

(1) N 例子用 K 标签中的一个标志:

$$D = \{x_n \in X, y_n \in Y = \{1, \dots, K\}\}_{n=1}^N。$$

(2) F 特征 $H = \{h_f : X \mapsto R^{d_f}\}_{f=1}^F$, 相关成本 c_f 。

(3) 预算敏感损失 L_B , 由成本预算 B 和丢失作用 $\ell(\hat{y}, y) \mapsto R$ 。

目的是找到一个**特征选择**策略 $\pi(x) : x \mapsto 2^H$ 和一个**特征结合分类器** $g(H_\pi) : 2^H \mapsto Y$ 使总预算敏感损失 $\sum L(g(\pi(x_n)), y_n)$ 最小。

一个选择特征子集 $H \cap \pi(x)$ 的成本是 $\sum_{h \in \pi(x)} c_h$ 。预算敏感的损失 L_B 有一个很强的预算约束, 它只接受 $\sum c_h \leq B$ 的答案。另外, L_B 是成本敏感的: 成本低的答案比成本较高的答案更有价值。后者性能的设计动机是即时性能; 我们应该能随时暂停算法的执行并得到最佳可能的答案。

通过理论分析, 触发器, 挂钟运行时间, 总 CPU 时间, 或者精确的电源消耗等的选择, 特征成本 c_f 能被灵活指定。我们相信现代数据中心的部署主要优化电源消耗, 没有测量功率的可靠方法, 我们用总 CPU 时间定义成本: 如果操作在多核上并行执行, 它的成本是所有内核上的总 CPU 时间。

在训练阶段, 我们的计算是无预算的, 我们能计算所有的特征来得到完整观察过的训练实例。在测试时有预算, 所以我们只能观察分类实例的一部分, 通过特征选择策略确定。我们推迟关于学习特征结合分类器 $g(H_\pi) : 2^H \mapsto Y$ 的讨论到 [3.4 部分](#)。现在我们假设 g 能结合特征的一个任意子集并提供一个分布 $P(Y = y)$ 。例如, g 可能是一个在完整观察数据上训练的 Naive Bayes (NB) 模型。

3.1 马尔可夫决策过程 (MDP) 的动态特征选择

为了建立特征选择策略 $\pi(x) : X \mapsto 2^H$ 模型, 我们介绍下马尔可夫决策过程 (MDP), 它为某个实例 x 定义了选择特征的单一插值。

定义 2. 特征选择 MDP 由 $(S, A, T(\cdot), R(\cdot), \gamma)$ 组成:

- (1) 状态 $s \in S$ 储存被选中的特征子集 $H_{\pi(x)}$ 和它们的值和总成本 $C_{H_{\pi(x)}}$ 。
- (2) 动作 A 的集合是特征 H 的集合。
- (3) (随机的) 状态变换分布 $T(s' | s, a)$ 取决于实例 x 。
- (4) 奖励功能 $R(s, a, s') \mapsto R$ 是手动确定的, 并取决于分类器 g 和实例 x 。
- (5) 在选择动作时数 γ 决定了前瞻量: 如果是 0, 基于动作的立即回报贪心选择动作; 如果是 1, 后续动作积累的回报被给予和即时动作的回报相同的权重。

在给定实例 x 上运行 MDP 得到一个轨迹 $\xi = (s_0, a_0, s_1, r_1, \dots, a_{I-1}, s_I, r_I)$, 其中 I 是采取行动的总数 (因此特征选择), s_0 是初始状态, $a_i \sim \pi(a | s_i)$ 被策略 $\pi(a | s)$ 和 $s_{i+1} \sim T(s | s_i, a_i)$ 选择, 且策略取决于 x 。MDP 插值的总期望回报(值)写为

$$V_{\pi}(s_0) = E_{\xi \sim \{\pi, x\}} r(\xi) = E_{\xi \sim \{\pi, x\}} \left[\sum_{i=0}^I \gamma^i r_i \right] \quad (1)$$

聚合这样的轨迹形成策略学习方法的基础。

3.2 定义回报

预算敏感的损失通过比较早期获

得的信息和后来获得的信息来执行即时性能。为了使这正式化, 考虑到图 1, 为某个实例 x 提供了在连续特征选择插值中每一个点的熵和 g 的 0-1 损失。对于最好的即时性能, 我们希望捕捉在损失相对的成本曲线上的大部分区域, 直到最大预算 B [17]。

回忆 (1) 插值 ξ 定义为获得的回报的总和。如果单一动作的回报定义为作为直接结果被捕捉的曲线上面的区域, 那么所有插值的值与 L_B 对应。

然而, 直接应用损失时有个问题: 只有第一步“倾斜”直接预测得到直接回报 (在图里是第一步)。需要一个更流畅的回报函数: 如果分类器 g 能给出一个完整分布 $P(Y = y | H_{\pi(x)})$ 而不仅仅是一个预测 $\hat{y} \in Y$, 我们能使选择子集得到的信息最大化而不是直接使 $g(\pi(x))$ 的损失最小化:

$$I(Y; H_{\pi(x)}) = H(Y) - H(Y | H_{\pi(x)}) = \sum_{y \in Y} P(y) \log P(y) - \sum_{y, H_{\pi(x)}} P(y, H_{\pi(x)}) \log P(y | H_{\pi(x)})$$

在某种程度上 g 是准确的, 信息获取最大化对应于损失最小化, 确保我们不仅做了正确的分类决定而且是最肯定的。因此, 如图一所示, 我们定义选择特征 h_s 回

报和 c_f 和设定值 H_s 计算得到 $I_{H_s}(Y ;$

$$h_f)(B_s - \frac{1}{2} c_f)。$$

虽然我们不在用这种方法计算，但是注意这个定义只计算中间设置和截止成本中的区域，很容易混合除了截止成本之外的设置成本。

3.3 参数化和学习策略

空间的限制禁止了加固学习技术的全面展示；[20]提供了一个全面的回顾。简而言之：我们寻找能使 MDP

(1) 期望值最大的技术。因此，动作必须根据它们的期望值选定：

$$\arg \max_a \pi(a|s) = \arg \max_a Q^*(s, a)$$

$Q^*(s, a)$ 是最佳动作值函数——在状态 s 采取行动 a 得到期望值直到插值的最后。因为状态代表了指数增长的子集和相关的真实值，所以不能准确代表 $Q(s, a)$ 。相反，我们应用特征近似并写出 $Q(s, a) = \theta^T \phi(s, a)$ ，其中， $\phi : S \times A \mapsto R^{d_s}$ 是状态特征化函数， d_s 是状态特征向量的维数， θ 是定义这个策略的权重向量。

特别地，该策略被定义为

$$\pi(a|s) = \frac{1}{Z} \exp\left(\frac{1}{\Gamma} \theta^T \phi(s, a)\right) \quad (3)$$

Z 是恰当的规范化，是在策略中控制探索与开发的温度参数。当达到顶峰；

它成为统一的

通常，我们从策略迭代得到。首先，我们通过用即时策略参数运行插值（到完成）来搜集样本。根据这些样本，在所有训练时所看到的状态下，值被计算，而且由一规范化最小平方方法给定为。

在训练过程中，我们搜集从一个随机可行的可能性为的状态或者最初的空状态开始的样本。参数随训练的重复次数指数衰减。如果在一个确定的集合上返回到确切的一致插值序列，训练就结束了。

与动态对应的静态的状态动作特征向量 特征函数从状态中提取下面的特征：

- (1) 长度 F 的位向量 \mathbf{m} ：最初所有位为 1，当相应的特征被计算时被设置为 0。
- (2) 对于每一个 h_j ，尺度向量 d_j 代表其值；直到被观察则为 0。
- (3) 成本特征 $c \in [0, 1]$ 代表成本花销分数。
- (4) 倾斜的特征 1。

这些特征定义了**动态**的状态，为形成闭环（动态的）策略提供了足够的信息，该策略能为不同的测试示例选择不同的特征。

静态的状态有上面除了观察特征值以外的所有特征。这个特点只能形成开环的（静态的）策略，该策略对所有示例来说是相同的。

$$\text{Input: } D = \{x_n, y_n\}_{n=1}^N; L_B$$

Result: Trained π, g

```

 $\pi_0 \leftarrow \text{random};$ 
for  $i \leftarrow 1$  to  $\text{max\_iterations}$  do
  States, Actions, Costs, Labels  $\leftarrow$ 
  GatherSamples( $\mathcal{D}, \pi_{i-1}$ );
   $g_i \leftarrow$  UpdateClassifier(States, Labels);
  Rewards  $\leftarrow$  ComputeRewards(States, Costs,
  Labels,  $g_i, \mathcal{L}_B, \gamma$ );
   $\pi_i \leftarrow$  UpdatePolicy(States, Actions,
  Rewards);
end
    
```

算法 1: 因为回报计算取决于分类器，而且状态分布取决于策略，被反复训练。

静态状态学习策略在实验中被当做基准线。

状态动作特征函数有效地模块编码这些特征：除了与考虑到的动作相对应的模块外，函数值均为 0。在实现时，我们训练 F 把回归和相关的规范化的 K-折叠杂交验证的参数区分开。

的影响 值得关注的是用这些特征和解决 MDP 找到了一个**静态的贪心策略**：在一个状态下采取行动的值就是期望获得的回报。当 $\gamma=1$ 时，采取行动的价值是图一中曲线上的所有区域，而且我们得到了静态的，非近视的策略——另一基准线。

3.4. 学习分类器

直到现在我们假设能结合特征的任意子集并提供分布 $P(Y=y)$ ——例如，在完整观察的数据上训练的高斯朴素贝叶斯 (NB) 模型。

自从区别分类器普遍提供了更好的性能，我们应用**逻辑回归**分类器时呈现了一个新挑战：在测试时，一些特征值丢失需要找到宿主。如果分类器是专门在完整的观察数据上训练的，那么在测试时特征值统计就会不匹配，导致很差的性能。因此，我们需要在展示了由策略引起的丢失的数据的形式的数据分布上得到分类器权重。同时，学习策略取决于用于回报计算的分类器。出于这个原因，策略和分类器需要被共同学习：**算法 1** 给出了迭代程序。

未观察值估算 不同于朴素贝叶斯分类器，逻辑回归分类器不能应用特征的任意子集 H_π ，相反能在混合大小的特征向量上运行。为了表示一个完整观察实例的特征向量，我们采用 $x = [h_1(x), \dots, h_f(x)]$ 。为了防止 $H_\pi \subset H$ ，我们需要在向量里填上未观察特征。

基本策略是平均数估算：用特征的平均值填入：

$$x_\pi = \left[h_i(x) : \begin{cases} h_i(x) & \text{if } h_i \in H_{\pi(x)} \\ h_i & \text{otherwise} \end{cases} \right]$$

(4)

如果我们假设 x 根据多元高斯 $x \sim N(0, \Sigma)$ 分布，其中 Σ 是样本协方差 $X^T X$ ，数据被标准化以得到零均值，然后

高斯估算就可以进行了。考虑到特征子集 H_π ，我们采用如下式子：

$$x_\pi = \begin{bmatrix} x^o \\ x^u \end{bmatrix} \sim N\left(0, \begin{bmatrix} A & C \\ C^T & B \end{bmatrix}\right)$$

(5)

其中 x^o 和 x^u 分别代表完全特征向量 x 观察了和未观察的部分，在这种情况下，未观察的变量与观察了的变量的比值上的分布由 $x^u | x^o \sim N(C^T A^{-1} x^o, B - C^T A^{-1} C)$ 给出。

学习一个以上的分类器 如图2所示，策略 π 选择特征子集比其他策略更频繁。相反只学习一个分类器 g 时它必须对所有观察到的特征子集鲁棒，我们能得到几个分类器，分给每个最频繁子集。在训练时完成了在遇到的特征子集上保持分布。对于每一个 K 最频繁子集，用在选择特征的位向量上汉明距离最接近的数据训练分类器。

每一个分类器用逻辑回归的 LIBLINEAR 结果训练，在每次迭代时用 L_2 规范化参数 K ——折叠的杂交验证方法。

4. 评价

我们评价下面的顺序选择基准线：

- **静态的，贪心的：** 与一个不观察特征值和贪婪地选择动作的策略的最好的性能相对应 ($\gamma = 0$)。

- **静态的，非近视的：** 不观察特征值但是应用 MDP $\gamma = 1$ 机制来考虑未来的动作回报的策略。
- **动态的，贪心的：** 观察特征值但是贪婪地选择动作的策略。




图2:MDP 的动作空间 A 是特征 H 的集合，用 ϕ 框表示。通过可能的特征子集（大框），状态空间的离散化变为可视化的；在图中被选中的特征为彩色的。特征选择策略 π 在特征子集上关于大框的阴影代表的资料组得到了一个分布。对于一个给定的预算 B ，不能得到所有的状态。在图中展示了状态空间的三种“预算削减”。

我们的方法是**动态的，非近视的**策略：观察到的特征值和完全预测。

在初步试验中，逻辑回归法总是比高斯朴素贝叶斯分类器运行得好，所以下面的实验只应用了前者。正如上面所描述的，我们在与平均估值相对应的高斯法和特征子集聚集下的不同数目分类器（1，3 和 6）中估算分类结果。我们发现平均估值比高斯估值好，而且虽然分类器数目增多可以提高性

能，但是会使我们的方法更容易过度拟合；
K=1 的分类器在所有任务中工作效果最好。

在相应象限上，可返回数据点的标志，否则
会有随机噪声。

4.1. 综合实验

在[25]之后，我们首先展示了策略像具有挑战性的综合实例中介绍的那样工作。在 D 维空间里，数据在每一个 2^D 象限都有一个标志，并由该象限的单位方差高斯法产生（见 3D 情况下的图 3 的左上方）。 D 廉价特征法返回相应维度的数据点坐标。对于每一个象限，还有一个昂贵特征法，如果数据点

在新数据点上的最优策略是用廉价特征法确定它的象限，然后采取相应的昂贵特征法的动作。需要强调的是通过我们的方法，我们成功地发现动态特征和非近视学习对于最优策略都是至关重要的。图 3 反映了这个最优策略的结果，该策略是一个随机的有不同的基准线的策略，而且我们是在考虑正确的最小预算的情况下训练我们的方法。

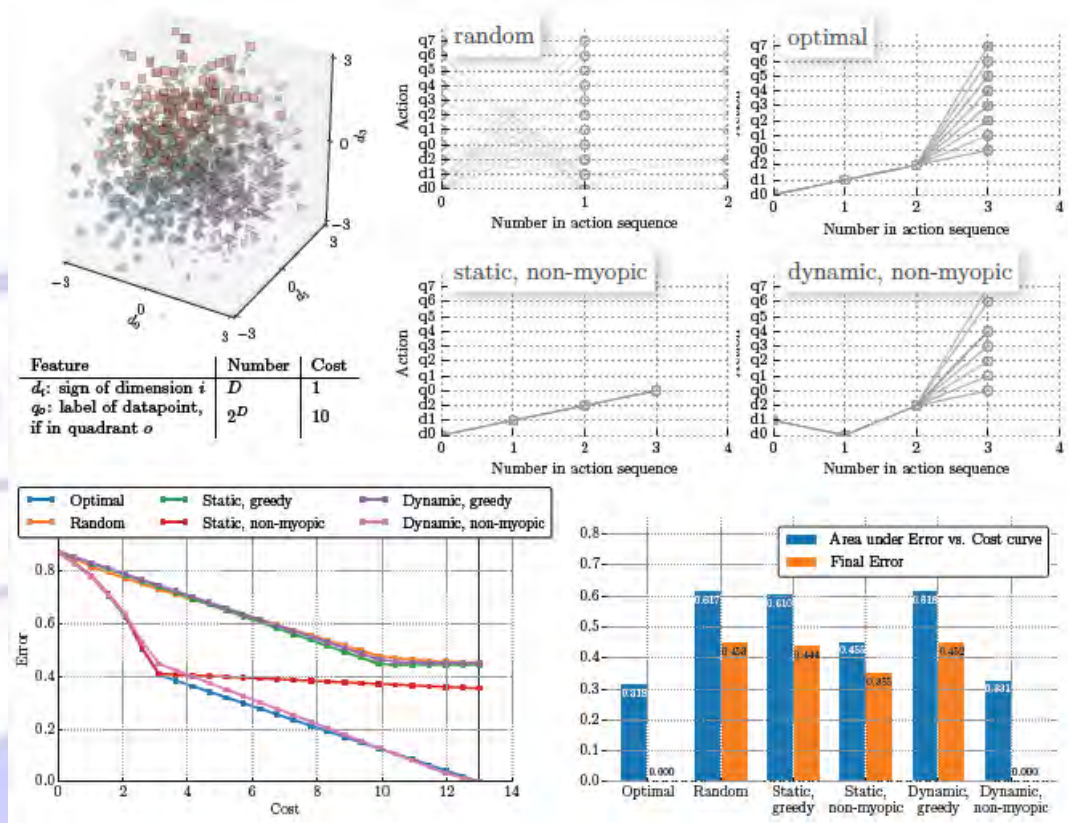


图 3: 综合实例评价 (用颜色明确表示)。数据和特征成本在左上显示；样本特征轨迹在右上。(在策略执行过程中边界不透明度与其普遍度相适应；节点不透明度与在该状态下获得的回报数对应。) 需要强调的是静态的，非近视的策略首先会准确地选择廉价特征，但是不能准确地分支命令，然而，动态的非近视的方法却得到了最佳策略。下半部给出了成本数的误差。

4.2. 场景识别

Scene-15 数据集[18]包含 4485 张 15 级可视化场景的图片。任务是根据场景将图片分类。后面的[24]，我们选取 14 个不同的视觉特征((GIST, HOG, TinyImages, LBP, SIFT, Line Histograms, Self-Similarity, Textons, Color Histograms 和变量)。特征的成本不同，从 0.3 秒到 8 秒，单一特征精确度也不同，从 0.32 (TinyImages) 到 0.82 (HOG)。在每个特征通道上用每级的随机的 100 张示例图片训练不同的多等级线性 SVMs。我们应用 liblinear 实现和 K-折叠交叉验证负参数 C。用在训练中未使用的图片评价经过训练的 SVMs，得到包含 210 个信任值的 2238 个向量的数据集：14 个特征通道中的每一个都有 15 个等级。这个数据集被分为 40-60 个进行训练并且为我们的实验测试集合。

图 4 展示了结果，包含所学习到的策略轨迹。对于所有估计的预算，我们的动态非近视的方法在成本曲线的误差度量面积上优于其他所有方法。我们在这个数据集上得到的结果与积极分类法[12] (图 2) 和贪心财奴法[26] (图 3) 的结果匹配，虽然两个

方法都用了一个额外的强大的特征通道 (ObjectBank)¹。

4.3. ImageNet 和最大化的特异性

完整的 ImageNet 数据集有超过 10K 个种类和超过一百万张图像[5]。这些类别被组织在一个层次结构里，可供新识别任务利用。我们在

“Hedging Your Bets” [6]中介绍的 65 级子集上评价这个数据集。在此次评价中，我们考虑初始特征计算已被完成的情况，这个任务是寻找一对现有分类器上的途径：与叶节点分类器的 Plattscaled SVM 的信任值相对应的特征 (在 SIFT-LLC 特征上训练)，并且每个特征具有成本 1[5]。[6]之后，精确度在所有节点都有定义，并且可通过合计子节点的概率获得内部节点的肯定值。

在后退预测节点时，我们结合我们的顺序特征选择法和 Hedging Your Bets” 法，考虑到成本预算的情况下，在给予最大限度的精确答案的同时用 ImageNet 层次去维持已得到保证的精确度。在图 5 中给出结果。当可用的预算增多时，我们的预测值的精确度 (由层次中的归一化信息增益定义) 也提高了，而精度保持不变。在 ILSVRC-65 层次上观察，发现预测值分

数在叶子节点上与现有计算时间同时增长。这个构想为人类视觉感知的时间过程的建模提供了一个新角度。

5. 结论和未来的工作

我们已经展示了怎样在即时目标下通过建造如同马尔可夫决策过程的相关过程类优化特征选择和分类策略。通过实验我们展示了策略如何在测试时间内适应计算过程已得到性能和效率的提升。除我们工作的初衷——视觉系统的实际部署方面之外我们想进一步探讨我们的模型作为一个工具去学习人类认知和视觉认知的时间过程的问题。

最后，最近视觉识别的卷积神经网络的成功打开了一个激动人心的新途径探索成本敏感性。深网络层可被视为我们系统的特征，通过适当的学习策略能优化直接计算。

致谢

这项研究是由国防科学和工程研究生奖学金, DARPA 慧眼和 MSEE 项目, NSF 奖金 IIS-0905647, IIS-1134072, 和 IIS-1212798; Toyota, 和英特尔视觉计算研究所支持的;

参考

- [1] D. Benbouzid, R. Busa-Fekete, and B. Keg1. Fast classification using sparse decision DAGs. In ICML, 2012. 2
- [2] L. Bourdev and J. Brandt. Robust Object Detection via Soft Cascade. In CVPR, 2005. 2
- [3] M. Chen, Z. Xu, K. Q. Weinberger, O. Chapelle, and D. Kedem. Classifier Cascade for Minimizing Feature Evaluation Cost. In AISTATS, 2012. 2
- [4] Y. Chen, H. Shioi, C. F. Montesinos, L. P. Koh, S. Wich, and A. Krause. Active detection via adaptive submodularity. In ICML, 2014. 2
- [5] J. Deng, A. C. Berg, K. Li, and L. Fei-fei. What Does Classifying More Than 10,000 Image Categories Tell Us ? In ECCV, 2010. 6, 7
- [6] J. Deng, J. Krause, A. C. Berg, and L. Fei-fei. Hedging Your Bets: Optimizing Accuracy-Specificity Trade-offs in Large Scale Visual Recognition. In

- CVPR, 2012. 7, 8
- [7] J. Deng, S. Satheesh, A. C. Berg, and L. Fei-fei. Fast and Balanced: Efficient Label Tree Learning for Large Scale Object Recognition. In NIPS, 2011. 2
- [8] G. Dulac-Arnold, L. Denoyer, P. Preux, and P. Gallinari. Sequential approaches for learning datum-wise sparse representations. Machine Learning, 2012. 2
- [9] G. Dulac-Arnold, L. Denoyer, N. Thome, M. Cord, and P. Gallinari. Sequentially generated instance-dependent image representations for classification. In ICLR, 2014. 2
- [10] R. Farrell, O. Oza, V. I. Morariu, T. Darrell, and L. S. Davis. Birdlets: Subordinate categorization using volumetric primitives and pose-normalized appearance. In ICCV, 2011. 1
- [11] L. Fei-Fei, A. Iyer, C. Koch, and P. Perona. What do we Perceive in a glance of a real-world scene? Journal of vision, Jan. 2007. 1
- [12] T. Gao and D. Koller. Active Classification based on Value of Classifier. In NIPS, 2011. 2, 6
- [13] A. Grubb and J. A. Bagnell. SpeedBoost: Anytime Prediction with Uniform Near-Optimality. In AISTATS, 2012. 2
- [14] H. He, D. Hal III, and J. Eisner. Cost-sensitive Dynamic Feature Selection. In ICML-W, 2012. 2
- [15] J. Hegde. Time course fo visual perception: Coarse-to-fine processing and beyond. Progress in Neurobiology, 2008. 1
- [16] S. Ji and L. Carin. Cost-Sensitive Feature Acquisition and Classification. Pattern Recognition, 2007. 2
- [17] S. Karayev, T. Baumgartner, M. Fritz, and T. Darrell. Timely

Object Recognition. In NIPS, 2012. 2, 3

[18] S. Lazebnik, C. Schmid, and J. Ponce. Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural

Scene Categories. In CVPR, 2006. 6

[19] M. J.-M. Mace, O. R. Joubert, J.-L. Nespoulous, and

M. Fabre-Thorpe. The time-course of visual categorizations: You spot the animal faster

than the bird. PLoS ONE, 2009. 1

[20] R. S. Sutton and A. G. Barto. Reinforcement Learning: An Introduction. MIT Press, 1998. 3

[21] K. Trapeznikov, V. Saligrama, and D. Castanon. Multi-Stage Classifier Design. Technical Report 617, 2013. 2

[22] P. Viola, O. M. Way, and M. J.

Jones. Robust Real-Time Face Detection. IJCV, 57(2):137 - 154, 2004. 1, 2

[23] D. Weiss, B. Sapp, and B. Taskar. Dynamic structured model selection. ICCV, 2013. 2

[24] J. Xiao, J. Hays, K. A. Ehinger, A. Oliva, and A. Torralba.

SUN database: Large-scale scene recognition from abbey to zoo. In CVPR, 2010. 1, 6


[25] Z. Xu, M. J. Kusner, K. Q. Weinberger, and M. Chen. Cost-

Sensitive Tree of Classifiers. In ICML, 2013. 2, 5


[26] Z. Xu, K. Q. Weinberger, and O. Chapelle. The Greedy

Miser: Learning under Test-time Budgets. In ICML, 2012.


2, 6



(a) Error given by policies learned for a budget = 5.



(b) Areas under error vs. cost curves of policies learned at different budgets.



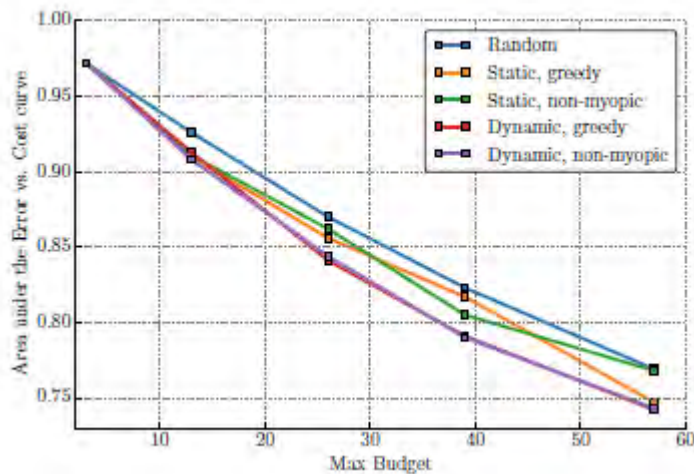
(c) Policy trajectories.

图 4: 场景-15 数据集的结果 (用颜色明确表示)。图 (a) 展示了 5 秒预算的策略学习成本图的误差。图 (b) 展示了不同策略和预算下的成本图度量误差的聚集面积, 表明了无论预算多少我们的方法都优于基准线。图 (c) 展示了动态策略的分支行为。

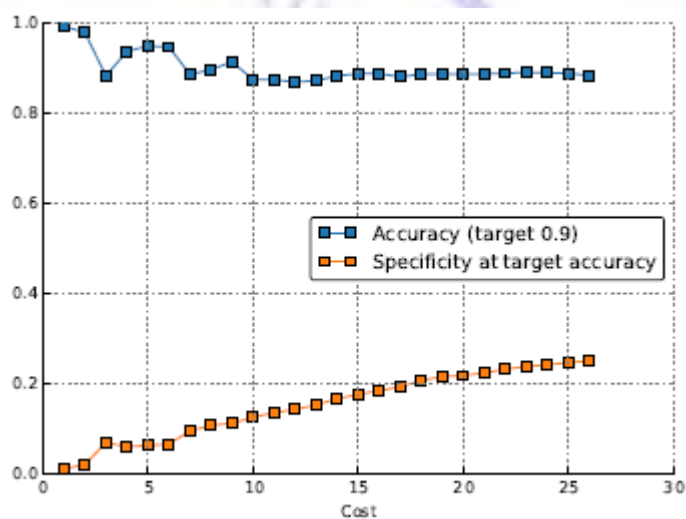
(a) 预算为 5 的策略学习误差

(b) 不同预算下的策略学习成本曲线的误差区域


(c) 策略轨迹



(a) 不同预算下的策略学习成本曲线的误差区域



(b) 保持预测准确度不变, 我们实现增长成本下的增长特异性 (动态的非近视的策略, 预算为 36)



(c) 我们使即时策略的不同成本点上的在 ILSVRC-65 的叶节点相应的内部节点上得到的预测值分数可视化：更多的计算使叶节点上的预测越来越准确

图 5: ILSVRC-65 数据集上的结果（用颜色明确表示）。图（a）展示了我们的动态方法在所有实际成本预算中都优于静态基准线。当我们的方法与 Hedging Your Bets [6] 结合，在即时策略中不变的预测精度得到实现，且预测精度随预测成本提高。图（b）和（c）展示了预算为 26 的动态非近视的策略学习。这类似于人类视觉性能，展示了较长刺激时间下的精度的提升。

