



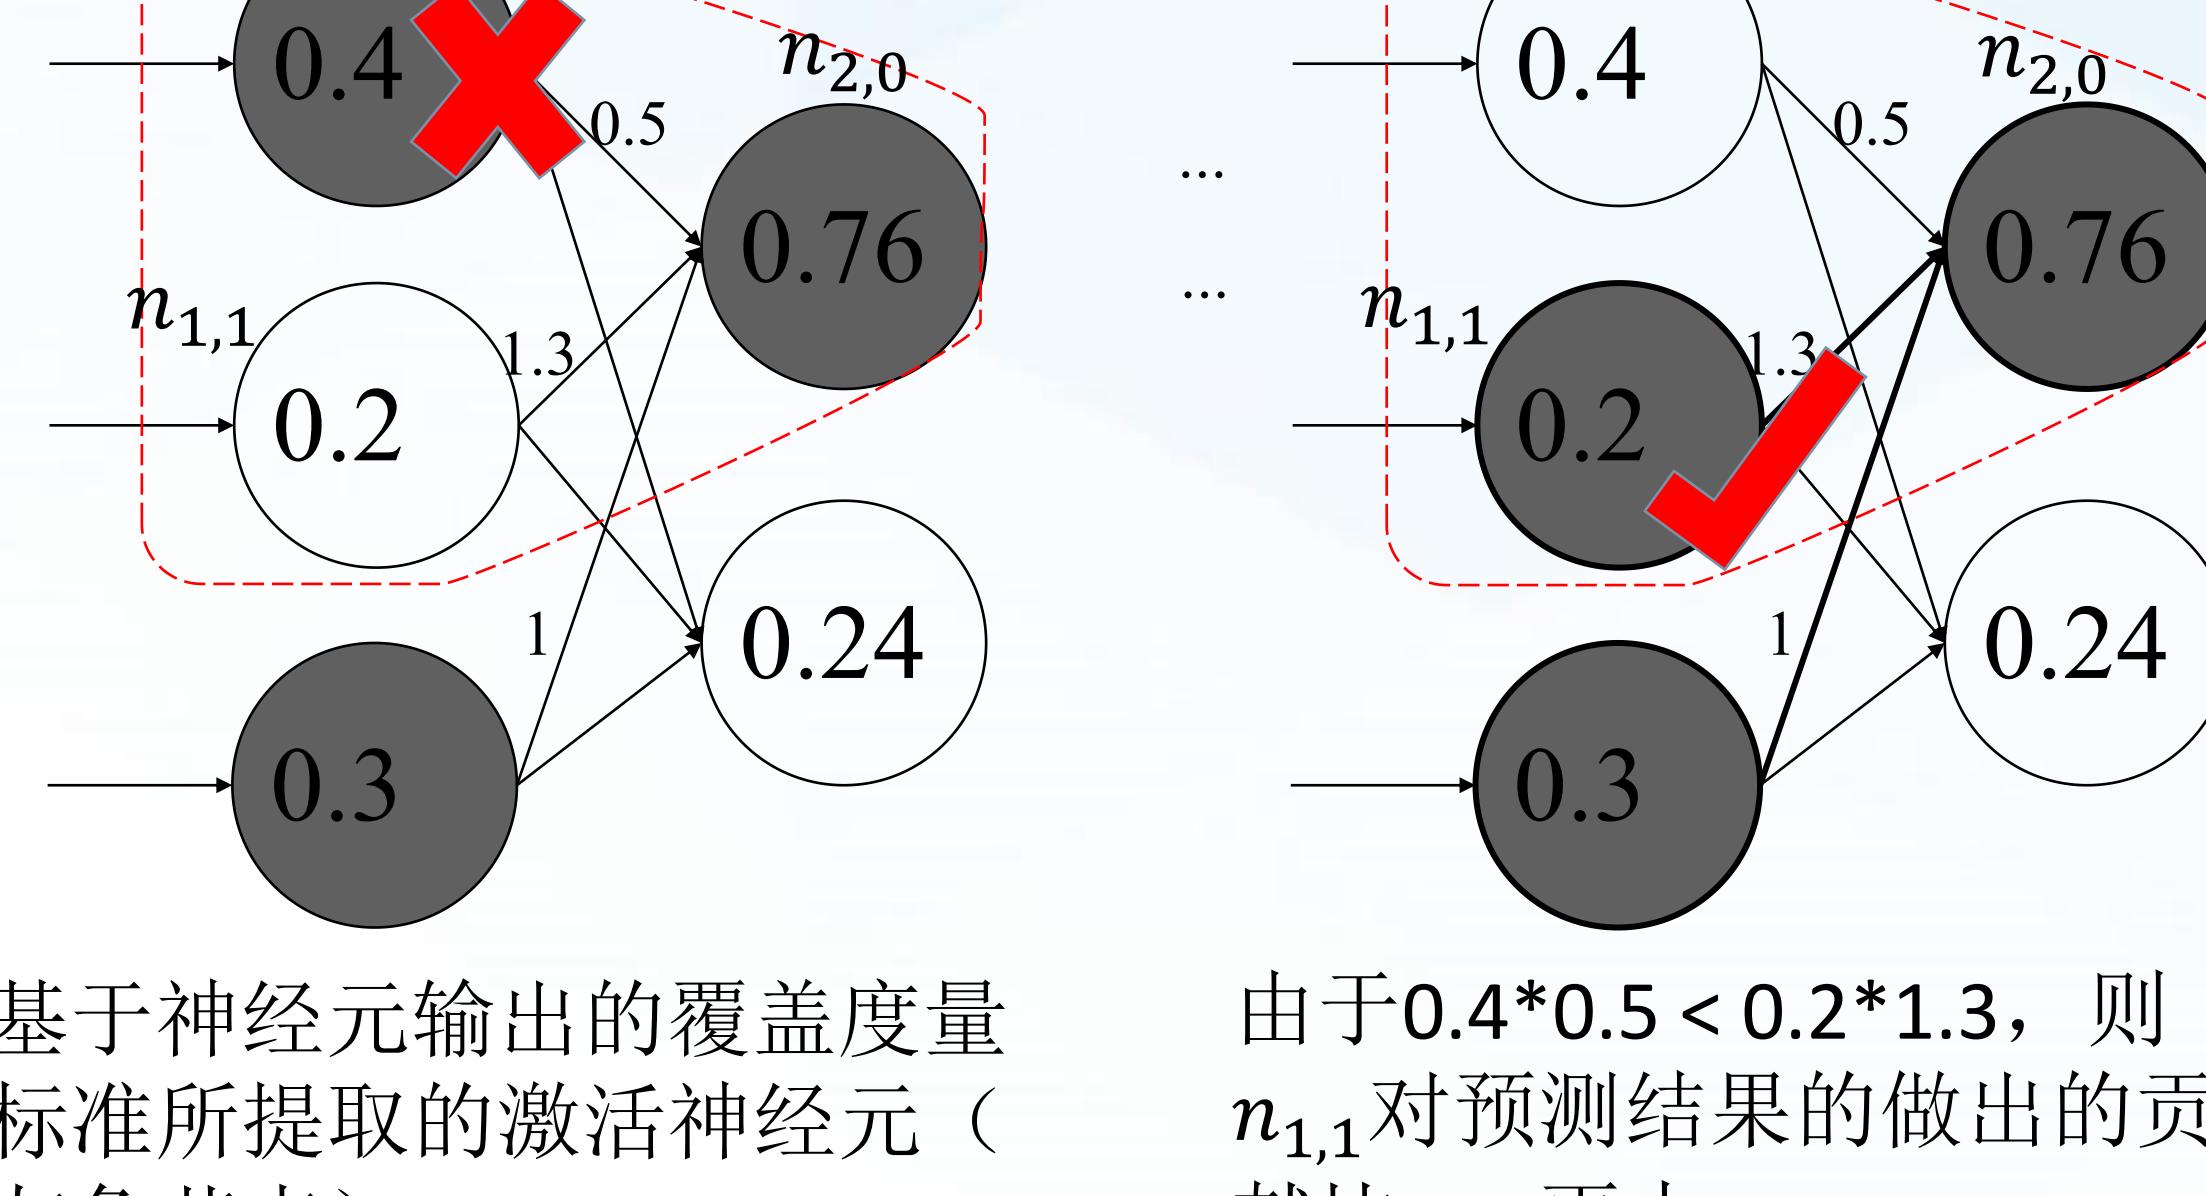
面向深度神经网络的贡献覆盖测试

(DeepCon: Contribution Coverage Testing for Deep Learning Systems, SANER 2021)

周志阳, 窦文生, 刘杰, 张晨昕, 魏峻, 叶丹

{zhouzhiyang18, wsdou, ljie}@otcaix.iscas.ac.cn

- 深度神经网络 (DNN) 广泛应用于安全敏感的领域, 需被充分地测试
- DNN的内部数据逻辑存于模型的神经元、权重、层中, 而非代码片段中, 需要制定新的覆盖度量标准来反映测试的充分性
- 基于神经元输出的覆盖度量标准^[1-3]的仅考虑到神经元而忽略了其射出的连接权重, 对重要“逻辑”的提取存“misfitting”



基于神经元输出的覆盖度量标准所提取的激活神经元 (灰色节点)

由于 $0.4 \times 0.5 < 0.2 \times 1.3$, 则 $n_{1,1}$ 对预测结果的做出的贡献比 $n_{1,0}$ 更大

一、贡献覆盖率度量标准 (DeepCon)

- “贡献”的定义: 从 n_1 到 n_2 的贡献 $u_{1,2} = n_{1,2} \cdot w^{1,2}$, 即
- “贡献”激活: 给定输入 x 和激活阈值 t , 如果:

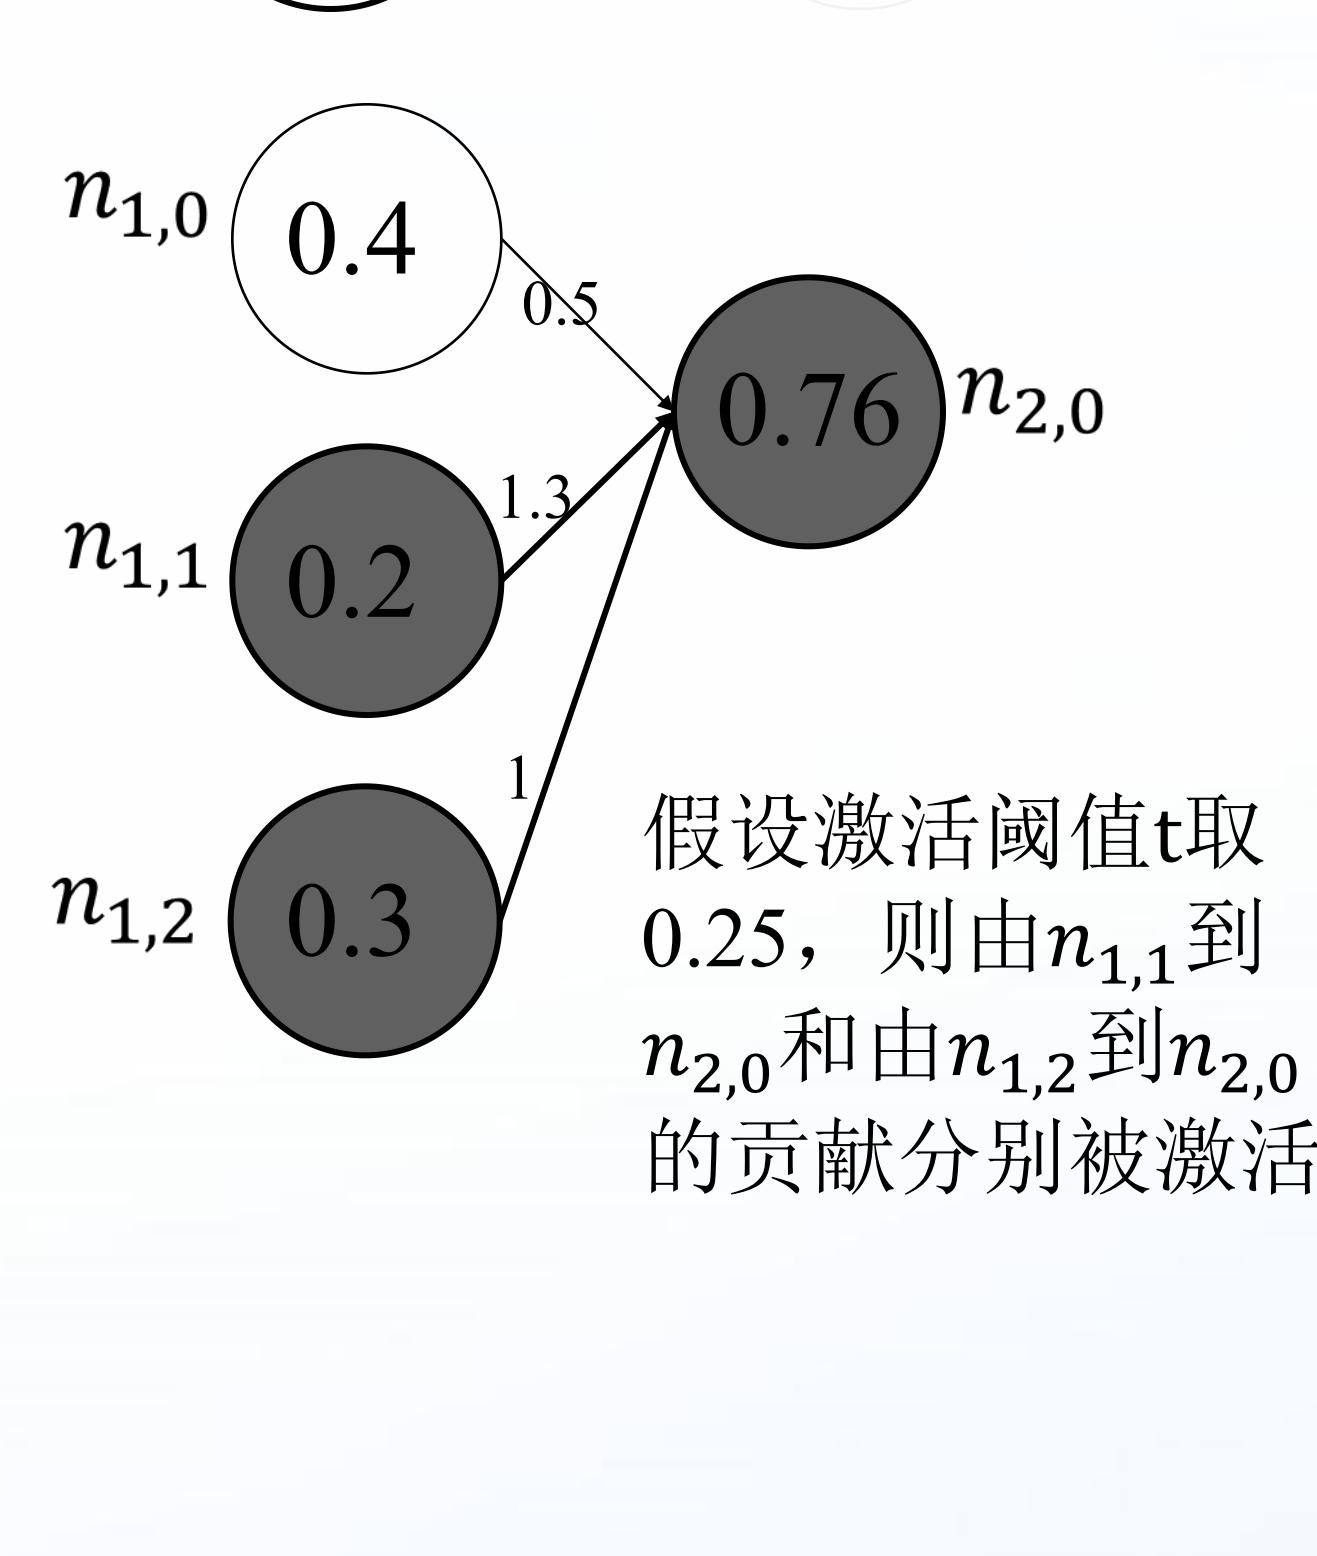
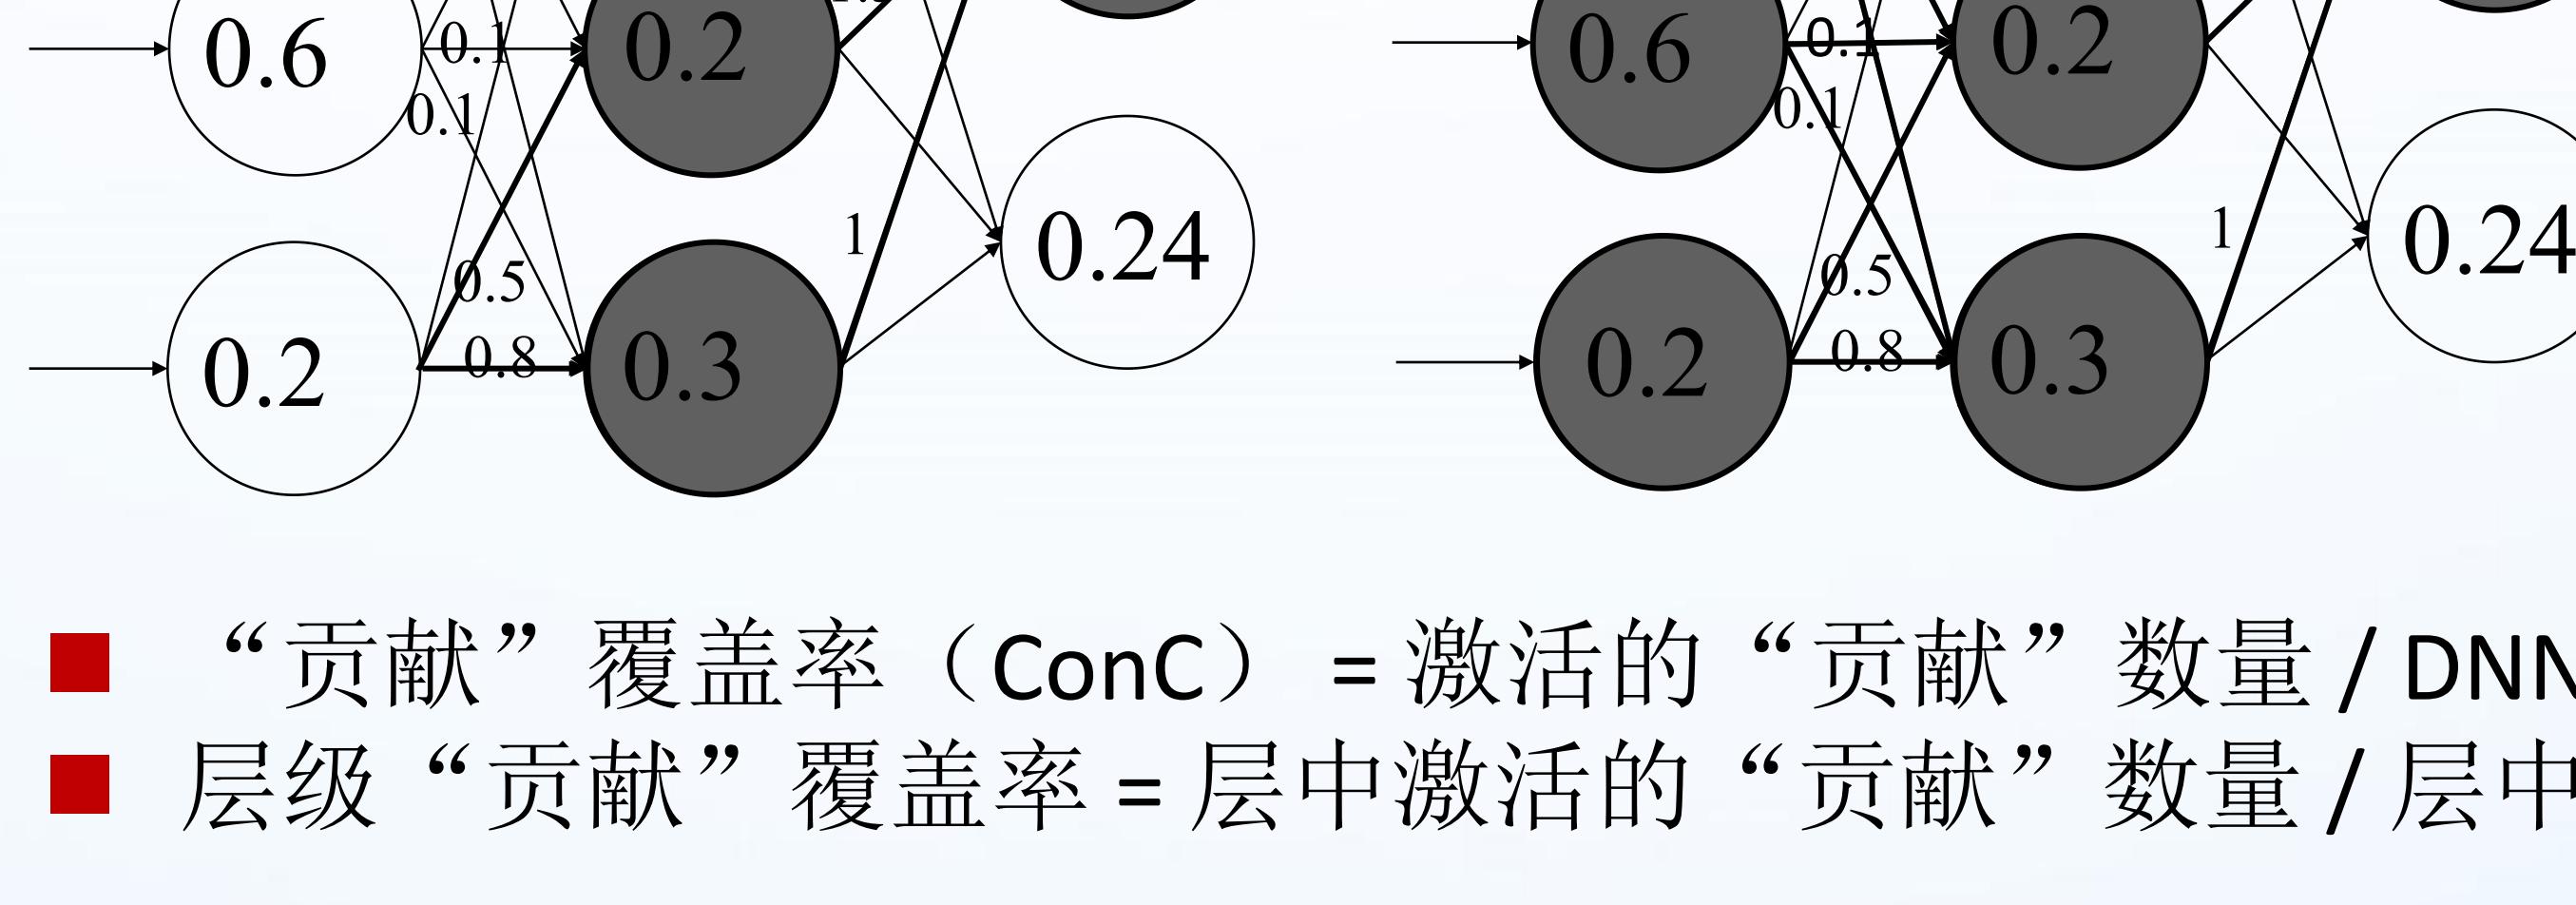
$$\text{normalized}(u(n_{1,2}, x)) = \frac{u(n_{1,2}, x) - \min(U(n_{1,2}, x))}{\max(U(n_{1,2}, x)) - \min(U(n_{1,2}, x))} > t$$

且神经元 n_2 被 x 激活, 则称 $u_{1,2}$ 被 x 激活。

注: 其中, $U(n_{1,2}, x)$ 表示连入 n_2 的贡献集合, 神经元 n_2 被 x 激活是指:

- (1) 当其是输出层神经元时, 其输出值最大
- (2) 否则, n_2 连入的任一贡献被激活

- 反向传递的“贡献”提取:



依据DNN对输入 x 的预测结果, 反向地从输出层到输入层逐层提取激活的“贡献”

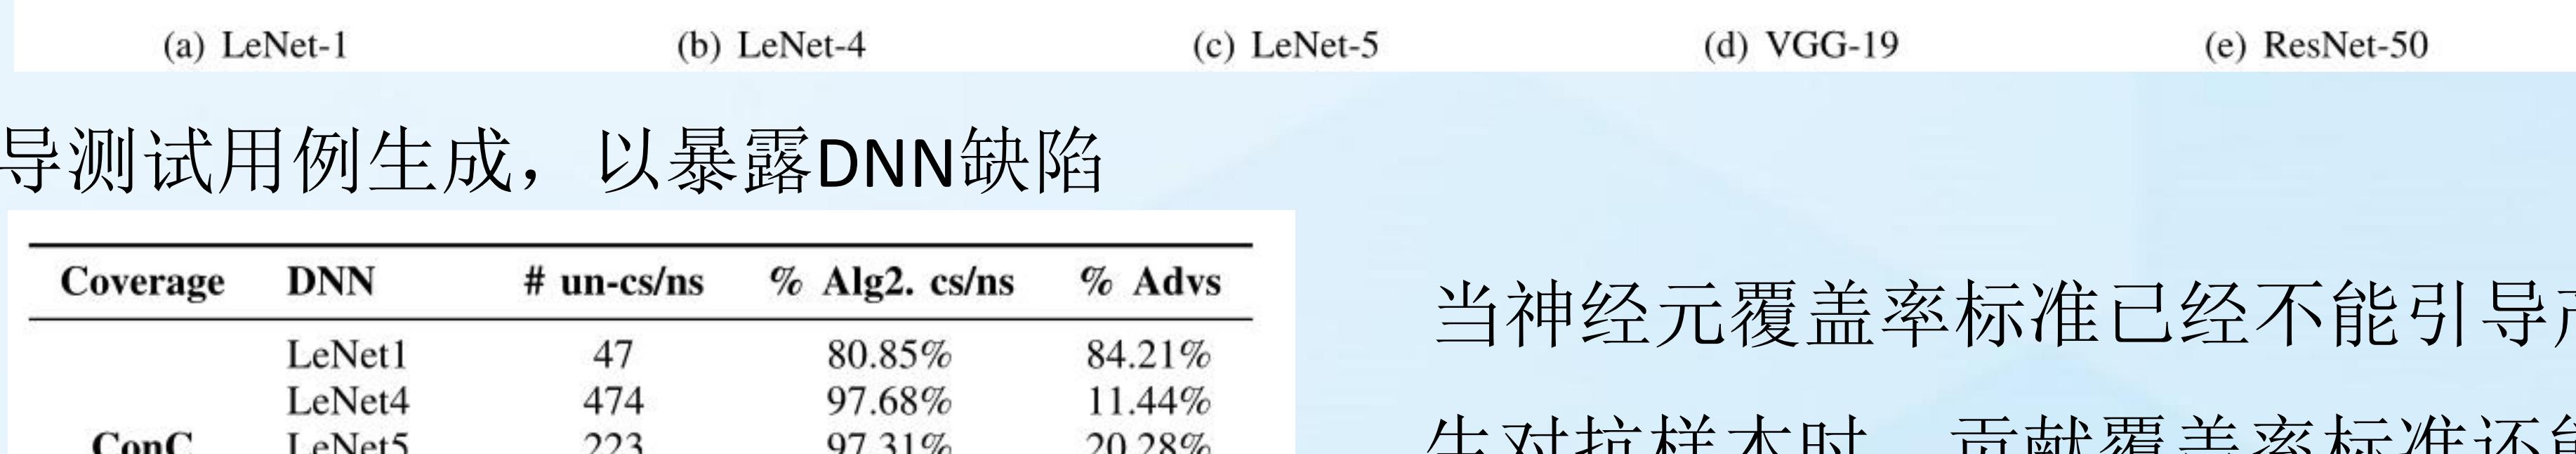
- “贡献”覆盖率 (ConC) = 激活的“贡献”数量 / DNN中总“贡献”数量
- 层级“贡献”覆盖率 = 层中激活的“贡献”数量 / 层中总“贡献”数量

二、贡献覆盖制导的测试输入生成 (DeepCon-Gen)

- 激活未被激活的“贡献”, 从而引导测试用例生成
- 把测试用例生成转化为优化问题, 构造联合目标函数: $\text{joint_obj} = \text{hinge_loss}(u_{1,2}(x), n_2(x))$
- 采用梯度上升方法求解, 使得未激活的贡献 $u_{1,2}$ 和神经元 n_2 的输出都变大

三、实验结果

- 和已有覆盖标准关于覆盖强度的比较: 远强于神经元覆盖标准, 具有暴露DNN更多“缺陷”的潜力



- 引导测试用例生成, 以暴露DNN缺陷

Coverage	DNN	# un-cs/ns	% Alg2. cs/ns	% Advs
ConC	LeNet1	47	80.85%	84.21%
	LeNet4	474	97.68%	11.44%
	LeNet5	223	97.31%	20.28%
	VGG-19	1,875,097	96.47%	99.88%
	ResNet-50	40,579	95.88%	97.24%
DNC	LeNet1	1	100.00%	0.00%
	LeNet4	0	0.00%	0.00%
	LeNet5	0	0.00%	0.00%
	VGG-19	22	40.90%	0.00%
	ResNet-50	14	57.14%	0.00%

当神经元覆盖率标准已经不能引导产生对抗样本时, 贡献覆盖率标准还能引导产生大量对抗样本, 具备更打暴露DNN缺陷的能力