

智能车辆的复杂场景感知 与学习技术研究进展

徐 昕

www.jilsa.net/xinxu.html

xinxu@nudt.edu.cn



國防科學技術大學

National University of Defense Technology

2017.04

主要内容

- 一、智能驾驶车辆的发展概况
- 二、智能车辆的复杂场景感知
- 三、基于学习的智能车辆自主决策和控制
- 四、智能车辆未来发展的思考

国内外智能车发展概况

- ❖ 近年来，美国、欧洲、日本等国的著名汽车厂商都非常重视智能驾驶汽车的研究，智能驾驶汽车已经被作为新一代汽车产业革命的主要突破点。
- ❖ **Google, Baidu**等信息领域的高新技术企业也加入到智能驾驶汽车关键技术研发的队伍中，并且进展迅速。
- ❖ 各国的主要科研机构 and 院校也十分重视智能车的研究，如美国**DARPA**，中国国家自然科学基金委员会等。



现有技术难点：复杂条件下完成自动驾驶



➤ 复杂地面状况



➤ 复杂天气条件

现有理论方法很难在复杂环境中实现环境感知、自主决策和控制的性能优化



➤ 复杂的道路交通环境

主要内容

- 一、智能驾驶车辆的发展概况
- 二、智能车辆的复杂场景感知
- 三、基于学习的智能车辆自主决策和控制
- 四、智能车辆未来发展的思考

智能车辆的复杂场景感知

- 视觉注意的多尺度频域分析模型
- 交通标志识别的深度-超限学习算法

基于全局抑制的视觉注意模型

❖ 注意建模的意义：

● 科学方面

- 注意机制始终是视听觉研究的核心问题之一；
- 探索并模拟人类注意力机制；

● 工程方面

- 当视觉系统检测目标和障碍时，注意机制将发挥重要作用
- 目标检测中，减少大范围搜索，为后续的精细处理提供指引
- 视觉注意还可以检测未曾定义的障碍物。（不需要学习！）



传统频域方法的局限性

- ❖ SR(Spectrum residual, Hou&Zhang, CVPR, 2007) 方法主要考虑了相位信息，丢弃了多数的幅值谱信息。

$$f(x, y) \xrightarrow{\mathcal{F}} \mathcal{F}(f)(u, v)$$



$$\mathcal{A}(u, v) = |\mathcal{F}(f)|$$

$$\mathcal{P}(u, v) = \text{angle}(\mathcal{F}(f))$$




$$\mathcal{L}(u, v) = \log(\mathcal{A}(u, v))$$

$$\mathcal{R}(u, v) = \mathcal{L}(u, v) - h_n \star \mathcal{L}(u, v),$$



$$\mathcal{S}(x, y) = g \star |\mathcal{F}^{-1}[\exp(\mathcal{R}(u, v) + i \cdot \mathcal{P}(u, v))]|^2$$



✓SR方法获得的显著区域与利用白噪声替换对数幅值谱获得的结果接近

White Noise
 $\log A_W(u, v) = W(u, v)$

基于全局抑制的视觉注意模型

❖ 基于频谱分析的全局抑制视觉注意模型

● 模型内容

- 提出从抑制非显著模式的角度来计算视觉注意；
- 指出图像的幅值谱上的尖峰对应于图像的非显著模式；
- 发现使用高斯核卷积图像幅值谱等价于视觉注意的计算。

● 理论意义

- 模型可以很好地预测人眼注意力；
- 模型可以模拟人类视觉系统中的全局抑制现象。

$$f(x, y) \xrightarrow{\mathcal{F}} \mathcal{F}(f)(u, v)$$



$$\mathcal{A}_{\mathcal{S}}(u, v) = |\mathcal{F}\{f(x, y)\}| \star h. \quad \mathcal{P}(u, v) = \text{angle}(\mathcal{F}(f))$$



$$\mathcal{S} = \mathcal{F}^{-1}\{\mathcal{A}_{\mathcal{S}}(u, v)e^{i \cdot \mathcal{P}(u, v)}\}.$$

基于全局抑制的视觉注意模型

❖ 采用超复数傅立叶变换(HFT)的显著性检测模型

$$f(n, m) = a + bi + cj + dk,$$

$$\mathcal{F}_{\mathcal{H}}[u, v] = \frac{1}{\sqrt{MN}} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} e^{-\mu 2\pi i ((\frac{mv}{M}) + (\frac{nu}{N}))} f(n, m),$$


$$\mathcal{A}(u, v) = \|\mathcal{F}_{\mathcal{H}}(u, v)\|,$$

$$\mathcal{P}(u, v) = \Phi(u, v) = \tan^{-1} \frac{\|\mathcal{V}(\mathcal{F}(u, v))\|}{\mathcal{S}(\mathcal{F}(u, v))} \Rightarrow \mathcal{S}_k = g \star \|\mathcal{F}_{\mathcal{H}}^{-1}\{\Lambda_k(u, v)e^{\mathcal{X}\mathcal{P}(u, v)}\}\|^2$$

✓g为高斯核

$$\Lambda(u, v; k) = (g(., .; k) \star \mathcal{A})(u, v).$$

$$k_p = \arg \min_k \{\mathcal{H}(\mathcal{S}_k)\}$$



✓ J.Li, M.Levin, J.An, X.Xu, and H.He. Visual Saliency Based on Scale-Space Analysis in the Frequency Domain, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(4): 996-1010

Model	Category 1		Category 2		Category 3	
	AUC	PoDSC	AUC	PoDSC	AUC	PoDSC
HFT	0.9424	0.7252	0.9146	0.5481	0.9351	0.4563
HFT(e)	0.9101	0.6592	0.9050	0.5112	0.9348	0.4502
HFT*	0.9543	0.7438	0.9425	0.6184	0.9572	0.5217
SR	0.8148	0.5104	0.8495	0.4321	0.9091	0.3281
PFT	0.8064	0.5029	0.8426	0.4292	0.9269	0.3780
SUN	0.8218	0.5393	0.8457	0.4522	0.8838	0.3026

✓ **J.Li, M.Levin, J.An, X.Xu, and H.He. Visual Saliency Based on Scale-Space Analysis in the Frequency Domain, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(4): 996-1010**

高速公路无人驾驶中的应用一

- 视觉注意在目标检测中的作用：



- 可以迅速定位出有意义的目标区域：例如标识牌，车辆；
- 有效避免大范围搜索，为后续的实时检测与识别奠定基础；

高速公路无人驾驶中的应用二

- 视觉注意模型可以检测未定义（学习）物体：




✓一个具体的例子：



基于眼动数据的视觉注意与场景理解

- ❖ 有任务时，人类注意不仅是自下而上的注意过程，同时还关注与交通事件相关的内容，比如车辆、交通标志等。



智能车辆的复杂场景感知

- 视觉注意的多尺度频域分析模型
- 交通标志识别的深度-超限学习算法

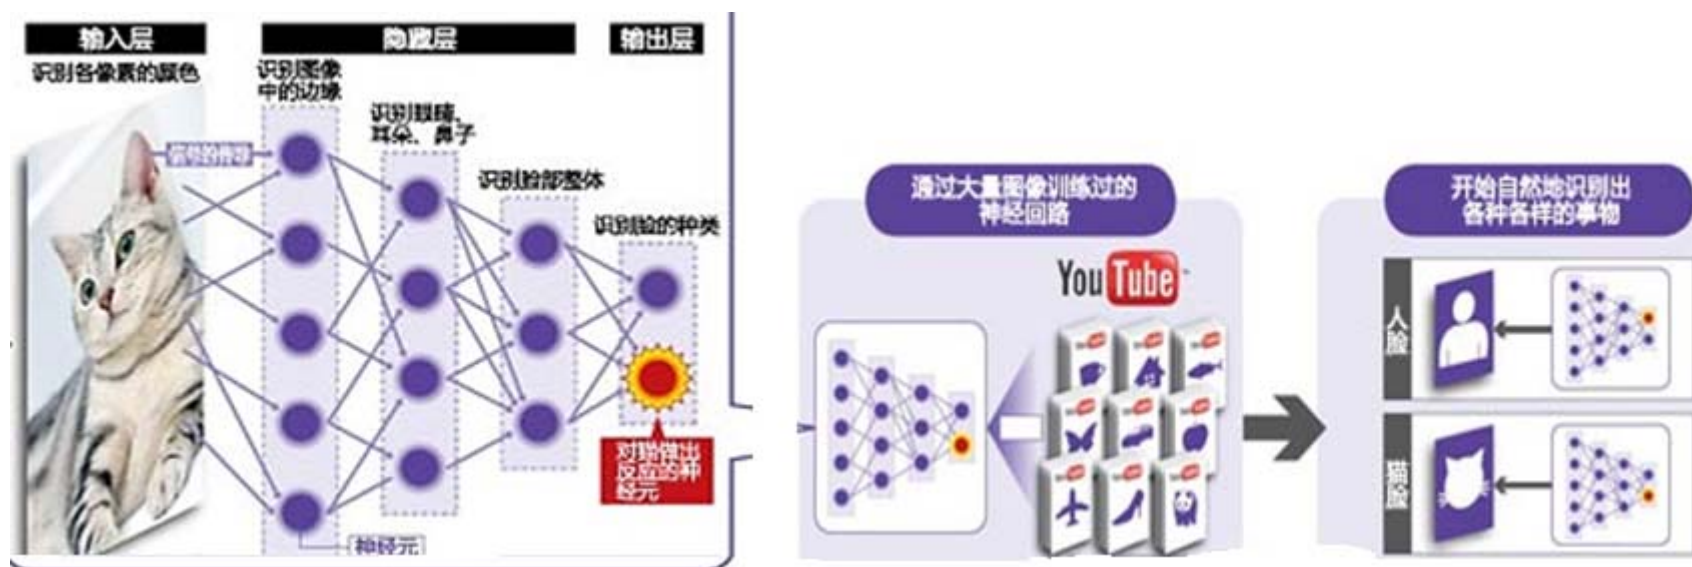
基于深度网络与超限学习的交通标志识别



- ❖ 交通路标处于复杂环境下，对比度下降、形变、过曝光、遮挡、模糊等多种不利因素使得传统的人工设计特征难以很好地进行表征
- ❖ 需要能对交通路标进行更加本质性刻画的特征，从而保证识别效果

基于深度网络与超限学习的交通标志识别

❖ 深度学习的特征学习能力



- ❖ 以深度卷积网络为模型结构基础，深度学习能够在以原始图像为输入的前提下，模仿大脑视觉皮层的信息处理机制进行逐层学习提取，最终得到高度抽象、更具本质刻画力的目标特征。

基于深度网络与超限学习的交通标志识别

❖ 经典深度卷积网络存在的不足


深度卷积网络基于梯度下降原理训练得到，并同时完成特征提取和分类，分类识别由网络中的全连接层完成，无法保证搜索到全局最优解，导致网络参数的次优性，分类泛化能力受限。

❖ 超限学习机(**extreme learning machines**)的分类优势

超限学习分类器能够保证在训练误差最小化的同时达到泛化能力的最大化，大量实验证实其相比于传统常规分类器具有更好的分类泛化能力。

基于深度网络与超限学习的交通标志识别


❖ 集成深度卷积神经网络的强大特征学习能力与超限学习机的快速训练和分类泛化能力优势



❖ 待识别的目标图像在简单预处理(图像均值约减)后输入深度卷积神经网络作特征提取，映射为特征向量，后由超限学习机判别分析，最终输出识别结果。其中，深度卷积神经网络只用作特征提取器，使用泛化性能更佳的超限学习机做分类

基于深度网络与超限学习的交通标志识别

❖ 深度卷积网络特征提取



- ❖ 网络构成：4层卷积层、3层最大池化层(完成深度卷积特征的学习提取)，2层全连接层(完成特征分类)


基于深度网络与超限学习的交通标志识别

❖ 超限学习机特征分类

- ❖ 随机初始化隐层节点参数，解析求解最小二乘解得到最优输出层参数

$$\mathbf{H}_{\mathbf{w}, \mathbf{b}, \mathbf{x}} \boldsymbol{\beta} = \mathbf{L}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m}, \quad \mathbf{L} = \begin{bmatrix} \mathbf{l}_1^T \\ \vdots \\ \mathbf{l}_N^T \end{bmatrix}_{N \times m}$$

$$\mathbf{H}_{\mathbf{w}, \mathbf{b}, \mathbf{x}} = \begin{bmatrix} f(\mathbf{w}_1 \cdot \mathbf{x}_1 + \mathbf{b}_1) & \dots & f(\mathbf{w}_M \cdot \mathbf{x}_1 + \mathbf{b}_M) \\ \vdots & \dots & \vdots \\ f(\mathbf{w}_1 \cdot \mathbf{x}_N + \mathbf{b}_1) & \dots & f(\mathbf{w}_M \cdot \mathbf{x}_N + \mathbf{b}_M) \end{bmatrix}_{N \times M}$$




$$\|\boldsymbol{\beta}\| = \|\mathbf{H}_{\mathbf{w}, \mathbf{b}, \mathbf{x}}^{\dagger} \mathbf{L}\| \leq \|\hat{\boldsymbol{\beta}}\|$$

- ❖ 所得解为**最小幅值**的最小二乘解，因而确保优化的分类泛化能力

基于深度网络与超限学习的交通标志识别


测试数据库：德国交通路标识别数据库(GTSRB), 提出方法
可达到**99.50%**的识别正确率，优于其他方法



✓ Zeng, Xu, et al. *IEEE Trans. on Intelligent Transportation Systems*, 2017, in press

路标检测标准数据库的建立

❖ 中国路标检测数据集




- ✓ 地域跨度大于800公里，包含高速、城区、乡村等多种交通场景
- ✓ 时间跨度超过8个月的，考虑不同天气、不同季节下的挑战性

主要内容



- 一、智能驾驶车辆的发展概况
- 二、智能车辆的复杂场景感知
- 三、基于学习的智能车辆自主决策和控制
- 四、智能车辆未来发展的几点思考

增强学习 (Reinforcement learning)



增强学习 (Reinforcement learning)

- ❖ 在与不确定的环境交互中学习
- ❖ 获取评价性的反馈信号
- ❖ 通常建模为Markov Decision Processes (MDP)



机器人自主学习面临的主要挑战


- ❖ **Curse of Dimensionality** – 状态空间的有效特征表示
- ❖ **Curse of real-world samples** – 更加高效的学习效率和泛化性能
- ❖ **Curse of Under-Modeling and Model Uncertainty** – 在线学习 vs. 鲁棒仿真学习
- ❖ **Curse of Goal Specification** -- 回报函数的自适应学习，多目标优化控制

若干研究进展

- ❖ 基于稀疏核特征的离线与在线增强学习
- ❖ 增强学习的流形特征表示
- ❖ 滚动时域的在线增强学习方法
- ❖ 基于增强学习的智能车辆优化决策与控制

增强学习的状态特征表示

❖ 机器人自主学习的状态表示





✓ **State: 20-dimensional continuous states**

✓ **Action: 7-dimensional actions**

✓ 2. 增强学习的流形特征表示

- ❖ 流形--Manifolds: a topological space in which each point has a neighborhood that has similar properties as a Euclidean space.
- ❖ 流形学习--Manifold learning: find low-dimensional representations while preserving some neighboring properties of the original data



✓ 2. 增强学习的流形特征表示

❖ Clustering-based graph Laplacian

- Sample clustering $J = \sum_{k=1}^K \sum_{i \in A_k} \|x_i - c_k\|_2$

- Manifold-based feature construction

- ✓ minimize $\sum_{i,j} \|\vec{\psi}_i - \vec{\psi}_j\|^2 W_{ij}$

$$L = D - W$$




✓ Compute eigenvectors for smaller eigenvalues

$$\vec{\phi}(x_i) = [\phi_1(x_i), \phi_2(x_i), \dots, \phi_l(x_i)] :$$

✓ 2. 增强学习的流形特征表示

❖ Clustering-based graph Laplacian for feature learning




✓ Nistrom expansion for new samples


$$\phi_m(x) = \frac{1}{1 - \lambda_k} \sum_{y \in kNN(x)} \frac{\omega(x, y)}{\sqrt{d(x)d(y)}} \phi_m(y)$$

$$m = 1, 2, \dots, l$$

2. 增强学习的流形特征表示



$$x_{t+1} = \text{bound}[x_t + \dot{x}_{t+1}];$$
$$\dot{x}_{t+1} = \text{bound}[\dot{x}_t + 0.001a_t - 0.0025 \cos(3x_t)],$$



✓ **Xu, et al.** A clustering-based graph Laplacian framework for value function approximation in reinforcement learning. *IEEE Transactions on Cybernetics* (2014,12), regular paper

3.滚动时域的在线增强学习方法

❖ 传统模型预测控制存在的不足

- **Open-loop optimal control policy** may not be adequate for disturbances and noises
- **Closed-loop linear optimal control** policies are sub-optimal for nonlinear systems
- Exact solution of the **Hamilton-Jacobi-Bellman** equation for nonlinear systems is computationally difficult, if not impossible

3.滚动时域的在线增强学习方法

- ❖ In order to get better performance
 - Open-loop optimal control policy may be replaced by general **closed-loop optimal policies**
 - In each prediction horizon, approximate dynamic programming (ADP) or reinforcement learning can be used to **approximate the closed-loop optimal control policies**
 - **Improved optimality with reduced computational costs**

3.滚动时域的在线增强学习方法




Fig. 1. Diagram of the receding-horizon DHP algorithm.

3.滚动时域的在线增强学习方法

✓Critic

$$\hat{\lambda}_{\tau}(e(\tau)) = w_c^T(\tau)\sigma(\nu_c^T(\tau)e(\tau))$$

✓TD error

$$\delta_{TD}^{[i]}(\tau) = \hat{\lambda}_{\tau}^{[i]}(e(\tau)) - E \left\{ \frac{\partial r(e(\tau), \hat{u}^{[i]}(\tau))}{\partial e(\tau)} + \left\{ \frac{\partial \hat{e}(\tau+1)}{\partial e(\tau)} \right\}^T \hat{\lambda}_{\tau+1}^{[i]}(\hat{e}(\tau+1)) \right\}$$

✓Weight update

$$\Delta w_c^{[i]}(\tau) = -\alpha_c \delta_{TD}^{[i]}(\tau) \frac{\partial \hat{\lambda}_{\tau}^{[i]}(e(\tau))}{\partial w_c^{[i]}(\tau)}$$

$$\Delta \nu_c^{[i]}(\tau) = -\alpha_c \delta_{TD}^{[i]}(\tau) \frac{\partial \hat{\lambda}_{\tau}^{[i]}(e(\tau))}{\partial \nu_c^{[i]}(\tau)}$$

3.滚动时域的在线增强学习方法

✓ Actor

$$J_{\tau}(e(\tau)) = E \left\{ F_{k+N}(e(k+N)) + \sum_{j=\tau}^{k+N-1} r(e(j), u(j)) \right\}$$

✓ Performance error gradient

$$\varepsilon^{[i]}(\tau) = E \left\{ \frac{\partial(r(e(\tau), \hat{u}^{[i]}(\tau)))}{\partial \hat{u}^{[i]}(\tau)} + \left\{ \frac{\partial \hat{e}(\tau+1)}{\partial \hat{u}^{[i]}(\tau)} \right\}^T \hat{\lambda}_{\tau+1}^{[i]}(\hat{e}(\tau+1)) \right\}$$

✓ Weight learning


$$\Delta w_a^{[i]}(\tau) = -\alpha_a \varepsilon^{[i]}(\tau) \frac{\partial \hat{u}^{[i]}(e(\tau))}{\partial w_a^{[i]}(\tau)}$$

$$\Delta \nu_a^{[i]}(\tau) = -\alpha_a \varepsilon^{[i]}(\tau) \frac{\partial \hat{u}^{[i]}(e(\tau))}{\partial \nu_a^{[i]}(\tau)}$$

3.滚动时域的在线增强学习方法


- ❖ **Convergence**: The convergence of the ADP algorithm in each horizon is proved by using the **two time-scale stochastic approximation** theory
 - Critic: Fast time scale
 - Actor: Slow time scale
- ❖ **Stability**: The stability of the closed-loop systems has been proved under certain conditions.

3.滚动时域的在线增强学习方法



- Lian, Xu, et al. Near-Optimal Tracking Control of Mobile Robots Via Receding-Horizon Dual Heuristic Programming. *IEEE Trans. Cybernetics* 46(11): 2484-2496 (2016)

3.滚动时域的在线增强学习方法





✓ 传统预瞄驾驶控制




✓ 自学习驾驶控制

• 基于Prescan的智能车辆三维可视化仿真




基于增强学习的无人车辆规划与控制

(2) 无人车辆自主优化决策的增强学习方法



如何根据仿真或实验获得的经验数据实现无人车辆并入车流和超车等驾驶行为的优化决策？

基于增强学习的无人车辆规划与控制



Typical driving behaviors

$$r_{speed} = \begin{cases} v_0 - v_{free} & v_0 < v_{free} \text{ 且 } l = 1 \\ v_0 - v_{free} - 0.2 & v_0 < v_{free} \text{ 且 } l = 2 \\ 0 & v_0 \geq v_{free} \text{ 且 } l = 1 \\ -0.2 & v_0 \geq v_{free} \text{ 且 } l = 2 \end{cases}$$

Reverse function design

✓ 利用离线增强学习训练的策略实现**在线自主决策**

✓ 能够有效实现动态车流条件下的变道、超车、保持车道等自主行为决策

✓ 相对传统基于专家规则的决策方法，**自学习的优化决策**能够利用经验数据不断提升性能



主要内容

- 一、智能驾驶车辆的发展概况
- 二、智能车辆的复杂场景感知
- 三、基于学习的智能车辆自主决策和控制
- 四、智能车辆未来发展的几点思考

我国人车协同智能驾驶发展建议

❖ 根据当前以及以后一定时期内的道路情况和智能驾驶技术储备，我们建议协同式发展思路：

将特定高速公路和城市主干道，设置为智能驾驶车道，**强制**车辆进行智能驾驶，并统一调度规划，允许智能车队通行。



我国人车协同智能驾驶发展建议


❖ 根据当前以及以后一定时期内的道路情况和智能驾驶技术储备，我们建议协同式发展思路：

其它复杂路段、非结构化道路，或在恶劣天气发生时，则**严格控制**启用智能驾驶。



数据驱动的人机交互与人机共驾理论与技术

✓数据驱动的驾驶员行为建模



✓智能驾驶系统的自学习
优化



欢迎批评指正