Journal of System Simulation

Volume 29 | Issue 9

Article 10

6-2-2020

Radar Emitter Signal Identification Based on SLIDE+SVM

Yingkun Huang College of Electrical Engineering Southwest Jiaotong University, Chengdu 610031, China;

Weidong Jin College of Electrical Engineering Southwest Jiaotong University, Chengdu 610031, China;

Follow this and additional works at: https://dc-china-simulation.researchcommons.org/journal

Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Radar Emitter Signal Identification Based on SLIDE+SVM

Abstract

Abstract: For the deficiency of traditional techniques of emitter signal feature extraction which heavily rely on experience, a model of radar emitting signal identification based on feature self-learning was proposed. This model consists of following 2 parts. *Firstly, transform radar signal into frequency domain, then reduce signal dimension by using improved Piecewise Aggregate Approximation (PAA) method. Secondly, create the model of multi-layer Liner Denoiser (LIDE) to feature learning by using unsupervised training method.* The validity of model was verified by simulating 5 different kinds of emitting signal with the outcome that excellent identification accuracy could be achieved at low SNR levels.

Keywords

radar emitter signal identification, piecewise aggregate approximation, liner denoiser, support vector machine

Recommended Citation

Huang Yingkun, Jin Weidong. Radar Emitter Signal Identification Based on SLIDE+SVM[J]. Journal of System Simulation, 2017, 29(9): 1944-1949.

第 29 卷第 9 期 2017 年 9 月

基于 SLIDE+SVM 的雷达辐射源信号识别

黄颖坤,金炜东

(西南交通大学电气工程学院, 四川 成都 610031)

摘要:针对依靠经验提取辐射源信号特征方法的不足,提出了一种基于自主特征学习的雷达辐射源 信号识别模型。该模型由 2 个部分组成:(1)将雷达信号变换到频域,利用改进的分段聚集近似表 示(Piecewise Aggregate Approximation, PAA)算法对信号降维;(2)构造多层线性降噪器(Linear Denoiser, LIDE)进行特征学习,模型采用无监督训练方法,构建一个 SVM 进行识别。通过仿真 5 种不同的辐射源信号验证了模型的有效性,结果表明该模型在低信噪比下能获得较好的识别正确率。 关键词:雷达辐射源信号识别;分段聚集近似表示;线性降噪器;支持向量机

中图分类号: TN973 文献标识码: A 文章编号: 1004-731X (2017) 09-1944-06 DOI: 10.16182/j.issn1004731x.joss.201709010

Radar Emitter Signal Identification Based on SLIDE+SVM

Huang Yingkun, Jin Weidong

(College of Electrical Engineering Southwest Jiaotong University, Chengdu 610031, China)

Abstract: For the deficiency of traditional techniques of emitter signal feature extraction which heavily rely on experience, a model of radar emitting signal identification based on feature self-learning was proposed. This model consists of following 2 parts. *Firstly, transform radar signal into frequency domain, then reduce signal dimension by using improved Piecewise Aggregate Approximation (PAA) method.* Secondly, create the model of multi-layer Liner Denoiser (LIDE) to feature learning by using unsupervised training method. The validity of model was verified by simulating 5 different kinds of emitting signal with the outcome that excellent identification accuracy could be achieved at low SNR levels.

Keywords: radar emitter signal identification; piecewise aggregate approximation; liner denoiser; support vector machine

引言

对于雷达对抗而言,雷达辐射源信号(Radar Emitter Signal, RES)识别是保证雷达干扰和反辐射 攻击有效发挥作战效能的重要前提^[1],它是在分选 的基础上,提取信号中雷达的工作参数和特征参



收稿日期:2017-05-19 修回日期:2017-07-14; 作者简介:黄颖坤(1989-),男,福建泉州,博士生, 研究方向为雷达信号处理、机器学习:金炜东(1959-), 男,安徽淮南,博士,教授,研究方向为智能信息处 理、系统仿真与优化方法。 数,然后利用这些参数获取该雷达目标的体制、用 途和型号、载体平台等信息,进而对战场态势、威 胁等级、活动规律、战术意图等进行推理,为己方 决策提供重要情报支持^[2-3]。RES 识别的一个研究 热点是提取辐射源信号的有效特征。传统的五参数 已经难以适应当前复杂的电磁环境,因此,一些时 域特征^[4]、频域特征^[5-6]、时频域特征^[7-8]等复杂特 征相继出现,并且取得了良好的效果。但是,应该 注意的是:人工特征的提取往往是费时费力,并且 这些人为设计的特征在 RES 识别系统的有效性和

普适性值得进一步研究^[9]。所以,一些欧美军事强 国开始将目光转移到依靠智能算法的自主特征学 习上^[10]。同时,国内一些学者,也有一些相关的 研究^[9,11]。从目前的资料来看,这些研究大多集中 在深度学习这一智能算法的研究上。

深度学习的研究热点之一是深度模型(DNN) 的构建。从 Geoffrey Hinton 开创深度学习的研究 和应用浪潮以来,大量 DNN 模型相继涌现,如栈 式降噪自编码器(SDAE)^[12]、深度限制玻尔兹曼机 (DBN)^[13]、卷积神经网络(CNN)^[14]、循环神经网络 (RNN)^[15]等。这些 DNN 模型已经在一些诸如:语 音识别、图像分类、自然语言处理等问题获得比以 往都要好的效果^[16-17],但不可忽视的是,DNN 模 型训练的高时间复杂性,需要强大的硬件设备支 持。一些学者尝试从模型上进行改进,以此降低模 型的训练时间。文献[18]提出了一种"栈式线性降 噪器(Stacked Linear Denoiser, SLIDE)"模型,从结 构上来看, 该模型较于 SDAE 具有明显的优势, 其一,SLIDE 模型不含隐层,模型的训练较为简单; 其二, SLIDE 模型只有 2 个需要设置的超参数。基 于此,本文提出一种基于"SLIDE+SVM"的 RES 识 别模型。对脉冲信号进行快速傅里叶变化, 接着用 改进的 PAA 算法对脉冲信号进行重表示,降低雷 达信号维数; 创建一个含有多层的 SLIDE 模型学 习输入的特征;构造一个 SVM 对学习到的特征进 行分类识别。

1 线性降噪器

1.1 单层线性降噪器

线性降噪器(Linear Denoiser, LIDE)模型从原 理上和降噪编码器(DA)类似,都是以一定的概率 "擦除"输入的某些特征,通过学习这些"破损"的特 征使模型更具鲁棒性。从结构上看,LIDE 模型不 包含隐层,只有输入和输出层(如图 1)。这样,LIDE 就可以看成是一个线性回归模型,该模型的输入层 和输出层的单元数相同。



Fig. 1 Model of LIDE

模型的原理:考虑模型的输入训练集 $X = [x_1, x_2, ..., x_n]$ $R^{d'n}$,其中, x_i \hat{I} $R^{d'1}$ 为一个 输入样本,这样 LIDE 线性模型就可以形式化的描述为:

$$\boldsymbol{y}_i = \boldsymbol{W} \boldsymbol{x}_i + \boldsymbol{b} \tag{1}$$

为了简化计算可以令向量 b=1,式(1)可以简化 为 $y_i = W' x'_i$,其中 $W' = [W,1] R^{d?(d-1)}$, $x'_i = [x^T_i$, 1]^TÎ $R^{(d+1)1}$,同时,假设每一个原始输入样本 x_i 有 m 个不同的"破损"版本,所以权值矩阵 W'的值 就是通过最小化这些"破损"输入与原输入之间的 误差来估计的。选择常见的平方损失函数:

$$L_{sq}(\boldsymbol{W}) = \frac{1}{2} \underbrace{\lim_{j=1}^{m_{sq}}}_{j=1}^{m_{sq}} \left\| \boldsymbol{x}_{i} - \boldsymbol{W}' \widehat{\boldsymbol{x}_{ij}}' \right\|^{2}$$
(2)

令 $\hat{\mathbf{x}}_{ij}$ 为原始输入 \mathbf{x}_i 第j个"破损"的输入,所 以 $\hat{\mathbf{x}}_{ij}^{'} = [\widehat{\mathbf{x}}_{ij}^{T}, 1]^{T}$ 。又令 $\overline{\mathbf{X}} = [\mathbf{X}, \dots, \mathbf{X}]$ $\mathbf{R}^{d'nm}$, $\widehat{\mathbf{X}} = [\widehat{\mathbf{x}}_{1,1}^{'}, \dots, \widehat{\mathbf{x}}_{1,n}^{'}, \widehat{\mathbf{x}}_{1,2}^{'}, \dots, \widehat{\mathbf{x}}_{n,m}^{'}]$ **î** $\mathbf{R}^{(d+1)'nm}$ 。这样,可以 定义两个向量积:

$$\boldsymbol{Q} = \frac{1}{m} \widehat{\boldsymbol{X}} \widehat{\boldsymbol{X}}^{\mathrm{T}} \neq \boldsymbol{P} = \frac{1}{m} \overline{\boldsymbol{X}} \widehat{\boldsymbol{X}}^{\mathrm{T}}$$

所以,式(2)用最小二乘法可以解得:

$$W' = PQ^{-1}$$

根据弱大数定理,当 *m* 足够大时,用样本的 期望来估计总体平均数是可靠的。所以当*m→∞*时, 权值矩阵 *W*′可表示为:

$$W' = E[P]E[Q]^{-1}$$

对于矩阵 Q,它的期望可以表示为 $E[Q] = \overset{n}{a} E$

第 29 卷第 9 期	系统仿真学报	Vol. 29 No. 9
2017年9月	Journal of System Simulation	Sep., 2017

 $[\hat{\mathbf{x}}_{k}(\hat{\mathbf{x}}_{k})^{\mathrm{T}}]$ 。用 $[A]_{ij}$ 来表示矩阵 A 的第i 行第j 列 的元素,所以随机变量的取值为:

为了便于描述, 令 $X' = [x'_1, \dots, x'_d, 1]^T$, 同时定 义 $S = X'(X')^T$ 。假设模型是以(1-*p*)的概率随机对原 始输入的特征置 0, 这里定义向量 $q = [p, \dots, p, 1]^T$ 。 这样随机变量矩阵 $[\widehat{x_k}'(\widehat{x_k}')^T]_{i,j}$ 的期望为:

 $E[\widehat{\boldsymbol{x}_{k}}^{'}(\widehat{\boldsymbol{x}_{k}}^{'})^{\mathrm{T}}]_{i,j} = \begin{bmatrix} \mathbf{J} & \text{if } i^{1} & j \\ \mathbf{J} & \text{if } i^{1} & j \\ \mathbf{J} & \mathbf{J} \end{bmatrix}_{i,j} \boldsymbol{q}_{i} \qquad \text{if } i = j$

同理,根据上面的步骤可以求得 E[P]的值。

1.2 栈式线性降噪器

深层模型有利于学习到样本更为深度、抽象的 特征,能有效提高模式分类的性能。单层的 LIDE 只是简单的线性变化,无法进行特征的学习,所以 需要构造一个多层的 LIDE 模型。通过堆叠多个 LIDE 模型可以构造一个相对复杂的 SLIDE 模型, 该模型的训练采用逐层贪婪训练法。

为了获得输入的非线性映射,在每一 LIDE 层 之间设置非线性激活函数,本文选择阈值函数:

 $T(x) = \begin{cases} 1 & x \ge t \\ 1 & 0 & x < t \end{cases}$

对于 SLIDE 第 k 层的输入可以表示为: $h^{k}=W^{k}T(h^{k}-1)$,因此模型的参数可用下列公式更新:

$$\boldsymbol{W}^{k} = \underset{\boldsymbol{W}}{\operatorname{argmin}} \left\| \boldsymbol{h}_{i}^{m_{i}} - \boldsymbol{W} \boldsymbol{h}_{ij}^{k-1} \right\|$$
(3)

式(3)的求解过程同式(2)相同。

2 辐射源信号的降维

现实截获的雷达脉冲信号在采样频率一定时, 由于脉宽参数的不同导致各脉冲的采样点数不一 致,为了训练同一个 SLIDE 模型,需要对脉冲数 据进行降维。脉冲数据是一组时序数列,因此也称 为时间序列的重表达。PAA 是一种常见的重表达 算法,它的优点是算法时间复杂度低、且能基本保 留数据原有形状(如图 2)。





PAA 算法标准定义如下:

假设序列 $Q=\{q_1,q_2,...,q_n\}$ 可用序列 $\hat{Q}=\{\hat{q_1},\hat{q_2},...,\hat{q_m}\}$ 来表示,这里Q的长度n与 \hat{Q} 的 长度m满足: $n \ge m$,且n能被m整除,令r=n/m, 则 \hat{Q} 中的元素为:

$$\widehat{q_i} = \frac{1}{r} \mathbf{\mathring{a}} \prod_{j=r^*(i-1)+1}^{r^*i} q_j \qquad 1 \le i \le n$$

上述算法要求 n 是 m 的整数倍,但是实际情况很难满足该条件,因此,本文对上述算法进行一 点变化,对 取:

$$r^* = \left\langle \frac{n}{m} \right\rangle$$

符号〈·〉表示对"·"取四舍五入。显然,对于 r^* 可能存在两种情形:当 $n < r^*$ m时,在序列 后补 0;当 $n > r^*$ m时,则删除序列中多余的元 素。改进 PAA 算法在雷达信号处理的具体步骤如 下所示。

第 29 卷第 9 期 2017 年 9 月

Algorithm 1: 改进 PAA 用于雷达信号处理算法 Input: 输入时序数列: $Q=\{q_1,q_2\cdots,q_n\}$; Initialize: m、n分别为时序数列 \hat{Q} 和Q的长度; If: n < m

• 对序列 Q 补 "0"后进行快速傅里叶变换: $\hat{Q} = ft(Q)$;

Else:

• 求得 $r^* = \left\langle \frac{n}{m} \right\rangle$;

当*n* < *r*^{*} *m* 时,在序列*Q*后补0;当*n* > *r*^{*} *m* 时,
 删除序列*Q* 中多余的元素;

- 对序列进行快速傅里叶变换: *sig=fft(Q)*,
 sig = {s₁, s₂,..., s_{s**m}};
- For: $i = 1, \dots m$
- $\widehat{q_i} = \frac{1}{r} \overset{*}{a} \sum_{j=r^* * (i-1)+1}^{r^* * i} s_j ;$
- End
- End

Output: 输出重表达后的时序序列(信号) $\hat{Q}=\{\hat{q_1}, \hat{q_2}, \dots, \hat{q_m}\}$,其中, $n \ge m$;

3 辐射源信号识别模型

文献[2]指出不同调制类型的雷达辐射源信号 存在唯一可分辨的频谱特征,因此,本文在暂不考 虑频域存在多个辐射源信号交叉干扰的情况下,构 建一个基于频谱数据的辐射源信号识别模型。

图 3 是本文提出的 RES 识别模型,大体上可 以分为 3 个部分。数据处理阶段的任务是将 RES 信号转化为适合 SLIDE 模型训练的输入。根据改 进的 PAA 算法可以快速的对雷达信号进行降维, 而且还基本保留了信号的形状;然后,构建 SLIDE 模型自动学习输入对象的特征。相较于一些经典的 DNN 模型,如 SDAE、DBN 等, SLDE 模型的参 数估计过程不采用梯度下降法,使得模型的训练时间很短,利于工程上的应用。另外,SLIDE 模型只有两个需要设置的超参数,分别为特征不为"0"的概率 *p* 和激活函数的门限 *t*,这两个参数可以通过交叉验证来选择。SLIDE 学习的特征可以直接作为分类器的输入,本文选择经典的 SVM 分类。

4 仿真实验

通过仿真 5 种常见的辐射源信号来验证本文 方法的有效性,包括常规雷达信号(CW)、线性调 频信号(LFM)、二相编码信号(BPSK)、二进制频率 编码信号(2FSK)和 Chirp 子脉冲步进频率信号 (CSF)。由于雷达信号的脉宽调制较为复杂,可以 是抖动、组变、捷变等等,因此,本文暂不考虑信 号的脉宽调制情况,只是简单的让不同辐射源的具 有不同的脉宽参数。其中, BPSK 采用 31 位伪随 机码, 脉宽为 1.8 µs; 2FSK 采用 13 位 Barker 码, 脉宽为 3.8 µs; CSF 的步进频率 5 MHZ, 脉宽为 2.8 μs; LFM 和 CW 的脉宽分别为 4.8 μs 和 5.8 μs。 另外,各辐射源信号的载频为 100 MHz,采样频率 为 500 MHz。在 20~30 dB 的信噪比范围内,每种信 号样式每隔5dB产生10个脉冲信号,总计150个脉 冲信号作为模型的训练样本。同时,分别在-5 dB, -2 dB, 0 dB, 2 dB, 5 dB 信噪比下各仿真 1 000 个 脉冲信号作为测试样本,每一信号样式各200个脉 冲。本次实验都是在 Matlab R2015b 平台下完成的, 同时选择 LibSVM3.1.12 和 DeepLearnToolbox 工具 箱分别搭建 SVM 模型和 SDA 模型。



Fig. 3 Model of RES identification based on SLIDE+SVM

第 29 卷第 9 期	系统仿真学报	Vol. 29 No. 9
2017年9月	Journal of System Simulation	Sep., 2017

实验 1: 作为对比的方法,本文分别选用 SDAE+Softmax(200-100-100-5)进行比较,并采 用 Deep Learn Toolbox 工具箱默认的参数。SLIDE 模型的两个参数设置为: *p*=0.6 和 *t*=0.2,模型的层 数 *s*=4,同时,设置 PAA 方法的参数 *m* 设为 200。 提取最后一层的输出作为 SVM 的输入,根据经验 选择高斯核函数进行训练,两种方法的识别结果如 表 1 所示。

从表1可以看出,低信噪比(SNR<0)的条件下本文提出的 SLIDE+SVM 识别模型相较与SDAE+softmax 模型具有明显的优势。在 SNR>2时,识别正确率略低于 SDAE+softmax 的方法。这是因为 LIDE 模型本质上是对输入数据进行降噪,所以在低 SNR 下可以表现出较好的性能。

表 1 分类方法的识别率比较 Tab. 1 Accurav rate of classification methods comparison /%

	信噪比 SNR/dB				
分尖力法	5	2	0	-2	-5
SDAE+Softmax	100	99.70	88.50	74.30	60.90
SLIDE+SVM	96.60	96.20	95.80	86.20	80.00

实验 2: 为了说明 LIDE 在训练速度上的优越性,分别用 DAE 和 LIDE 模型来训练 1 000 个辐射源信号样本所耗费的时间进行比较。本次测试平台为 Pentium Dual-Core 2.10 Hz,内存为 2GB RAM。实验重复 10 次求取其平均,结果如表 2 所示。

表 2	训练时间对比
Tab. 2 The t	raining time comparison
模型	时间/s
DAE	6.375
LIDE	0.578

从表 2 可以看出, DAE 的训练时间约为 LIDE 的 11 倍, 这是因为 LIDE 不采用梯度下降来优化 网络, 模型的训练不经过多次的迭代, 所以 LIDE 的训练速度大大优于 DAE。

5 结论

本文提出了一种基于 SLIDE+SVM 的 RES 识

别模型,并通过仿真 5 种常见 RES 信号进行验证。 实验 1 的结果表明了相较于传统 SDAE 模型,本 文提出的基于 SLIDE 模型在低信噪比(SNR<0)下 获得了更好的结果,这在工程应用中更具有现实意 义;同时,通过实验 2 表明了 SLIDE 在训练速度 上远优于 SDAE 模型,有助于实时辐射源信号的 实时处理。但是,难以忽视的是,本文提出的模型 对于参数设置较为敏感,具体表现为 PAA 算法对 于序列 *Q* 的长度 *m*,以及 SLIDE 模型的 *p* 和 *t* 参 数的选取较为困难。

参考文献:

- [1] 候印鸣. 综合电子战 [M]. 北京: 国防工业出版社, 2000: 1-32. (Hou Yinming. Synthetic EW [M]. Beijing, China: National Defense Industry Press, 2000: 1-32.
- [2] 余志斌. 基于脉内特征的雷达辐射源信号识别研究
 [D]. 成都:西南交通大学, 2010. (Yu Zhibin. Study on radar emitter signal identification based on intra-pulse features [D]. Chengdu, China: Southwest Jiaotong University, 2010.)
- [3] 张国柱. 雷达辐射源识别技术研究 [D]. 长沙: 国防 科学技术大学, 2005.(Zhang Guozhu. Research on emitter identification [D]. Changsha, China: National University of Defense Technology, 2005.)
- [4] 韩俊,何明浩,朱振波,等.基于复杂度特征的未知 雷达辐射源信号分选 [J].电子与信息学报,2009, 31(11): 2552-2556. (Han Jun, He Minghao, Zhu Zhenbo, et al. Sorting unknown radar emitter signal based on the complexity characteristics [J]. Journal of Electronics & Information Technology, 2009, 31(11): 2552-2556.)
- [5] Zhang X L, You W T, Guo Q, et al. Recognition Method Studies for Radar and Communication Signals Based on Spectral Correlation [C]// International Symposium on Systems and Control in Aeronautics and Astronautics. Piscataway, NJ, USA: IEEE Press, 2010: 363-366.
- [6] Ojeda O A Y, Grajal J. CFAR Detectors for Unknown Signals Based on The Spectral Correlation Measurement [C]// IEEE International Radar Conference. Virginia, USA: IEEE, 2005: 944-949.
- [7] Tavakoli E T, Falahati A. Radar Signal Recognition by CWD Picture Features [J]. International Journal of Communications Network & System Sciences (S1913-3715), 2012, 5(4): 238-242.
- [8] Han S K, Kim H T, Park S H, et al. Efficient Radar Target Recognition Using a Combination of Range

Profile and Time-Frequency Analysis [J]. Progress in Electromagnetics Research (S1559-8985), 2010, 108(4): 131-140.

- [9] 周志文,黄高明,高俊,等. 一种深度学习的雷达辐射源识别算法 [J]. 西安电子科技大学学报, 2017, 44(3): 85-90. (Zhou Zhiwen, Huang Gaoming, Gao Jun, et al. Radar emitter identification algorithm based on deep learning [J]. Journal of Xidian University, 2017, 44(3): 85-90.)
- [10] 袁成. DARPA 发展全新的雷达目标识别技术
 [EB/OL]. (2015-08-10) [2017-05-18]. http://www.dsti.net/ Information/News/95526. (Yuan C. DARPA Develops a new radar target identification technology [EB/OL].
 (2015-08-10) [2017-05-18]. http://www.dsti.net/ Information/News/95526.)
- [11] 周东青,王玉冰,王星,等. 基于深度限制波尔兹曼 机的辐射源信号识别 [J]. 国防科技大学学报, 2016, 38(6): 136-141. (Zhou Dongqing, Wang Yubing, Wang Xing, et al. Radar emitter identification algorithm based on deep restricted Boltzmann machine [J]. Journal of National University of Defense Technology, 2016, 38(6): 136-141.)
- [12] Vincent P, Larochelle H, Lajoie I, et al. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local

- -

(上接第1943页)

- [8] Zhou J. Traffic Signal Coordination Control of City Arterial Road that Based on Graphic Method [C]// International Conference on Electronic and Mechanical Engineering and Information Technology. USA: IEEE, 2011: 3562-3566.
- [9] Guo L, Yang R, Zhang M. Arterial Traffic Two-Direction Green Wave Coordination Control Based on MATLAB Graphical Method [C]// International Conference on Information Science and Control Engineering. USA: IEEE, 2015.
- [10] Davood K, Assef Z, Saeed B. Coordinated Signal Control for Arterial Intersections Using Fuzzy Logic [J]. Central European Journal of Engineering (S2081-9927), 2013, 3(3): 436-445.
- [11] 杨晓光,周光伟,杭明升,等. 公交优先技术方法 [J].
 城市交通, 2000 (2): 1-12. (Yang X G, Zhou G W, Hang M S, et al. Bus Priority Technology Method [J]. Urban

Denoising Criterion [J]. Journal of Machine Learning Research (S1532-4435), 2010, 11(12): 3371-3408.

- [13] Hinton G E, Salakhutdinov R R. Reducing the Dimensionality of Data with Neural Networks [J]. Science (S0036-8075), 2006, 313(5786): 504-507.
- [14] Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks [C]// International Conference on Neural Information Processing Systems. New York, NY, USA: ACM, 2012: 1097-1105.
- [15] Liu S, Yang N, Li M, et al. A Recursive Recurrent Neural Network for Statistical Machine Translation [C]// Proceedings of Meeting of the Association for Computational Linguistics, Maryland, USA, USA: The Association for computational Linguistics, 2014: 1491-1500.
- [16] Bengio Y, Courville A, Vincent P. Representation Learning: a Review and New Perspectives [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence (S0162-8828), 2013, 35(8): 1798-1828.
- [17] Lecun Y, Bengio Y, Hinton G. Deep Learning [J]. Nature (S0028-0836), 2015, 521(7553): 436-444.
- [18] Xu Z E, Weinberger K Q, Sha F. Rapid Feature Learning with Stacked Linear Denoisers [C]// ICML 2011 Workshop on Deep Learning and Unsupervised Feature Learning, Bellevue, USA, 2011. USA: ICML, 2001.

Transport of China, 2000 (2): 1-12.)

- [12] Lee D H, Wei H. A New Methodology for Multi-level Bus Prioritization at Signalized Intersections [C]// Transportation Research Board 84th Annual Meeting, 2004. Washington DC, USA: Transportation Research Board, 2004.
- Eichler M, Daganzo C F. Bus Lanes with Intermittent Priority: Strategy Formulae and an Evaluation [J]. Transportation Research Part B Methodological (S0191-2615), 2006, 40(9): 731-744.
- [14] Xiao H Z, Zhen L L, Yang Z C. Hybrid Control Based on q-learning for Urban Traffic Signal [J]. Journal of System Simulation (S1004-731X), 2006, 18(10): 2889-2894.
- [15] Abdulhai B, Pringle R, Karakoulas G J. Reinforcement Learning for True Adaptive Traffic Signal Control [J]. ASCE Journal of Transportation Engineering (S0733-947X), 2003, 129(3): 278-285.