

基于循环神经网络的卫星幅相信号调制识别与解调算法

查 雄, 彭 华, 秦 鑫, 李天昀, 李 广
(中国人民解放军战略支援部队信息工程大学, 河南郑州 450001)

摘 要: 针对卫星通信中常用的幅相调制信号, 提出了一种基于循环神经网络的信号识别与解调模型. 通过循环神经单元直接对信号时序进行深层特征提取, 结合全连接神经网络对特征进行维度映射, 最终完成目标信号的调制识别与解调. 该方法不需要预估目标信号载噪比, 克服了人为确定阈值的缺陷, 对信号频偏误差、定时误差容忍能力强; 且在开发维护和更新拓展方面, 克服了传统算法需重新部署判决规则的缺点, 符合实际工程需求. 仿真实验表明, 当网络训练达到稳态时, 在信噪比为 6dB 的条件下, 目标信号识别率接近 98%, 解调误码率接近理论门限. 本文所建立的理论形式为当今智能化信号处理提供了新思路, 其思想同样可应用于其他通信信号处理领域.

关键词: 调制识别; 信号解调; 特征提取; 循环神经网络; 智能化处理

中图分类号: TN911.7 **文献标识码:** A **文章编号:** 0372-2112 (2019)11-2443-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.11.029

Satellite Amplitude-Phase Signals Modulation Identification and Demodulation Algorithm Based on the Cyclic Neural Network

ZHA Xiong, PENG Hua, QIN Xin, LI Tian-yun, LI Guang
(PLA Strategic Support Force Information Engineering University, Zhengzhou, Henan 450001, China)

Abstract: A cognitive signal recognition and demodulation model is designed based on the cyclic neural network for conventional amplitude-phase satellite modulations. Through the cyclic neural unit, the features of the target signal are extracted. And the features are dimension-mapped by the fully connected neural network. The model finally completes the modulation recognition and demodulation of the target signal with these mapped features. This method does not need much prior knowledge about signal-to-noise ratio (S/N), and it is not sensitive to frequency offset. The method also has good adaptability in the maintenance and extension, which conforms to the demands of the engineering, while the traditional algorithms need to redeploy the decision rule. Computer simulations show that the correct recognition probability is close to 98% when S/N is greater than 6 dB and demodulation error rate is close to the theoretical gate. The presented theoretical form provides a new idea for intelligent signal processing, and it can also be used in other communication signal processing fields.

Key words: modulation recognition; signal demodulation; cyclic neural network; intelligent processing

1 引言

信号的调制识别^[1]是指已知信号所在的调制集合, 正确识别目标信号的调制类型, 是通信侦察以及软件无线电领域的一个重要研究课题. 而信号解调作为进一步获取信号深层信息的手段, 在民用或是军用领域都有着相当大的需求. 卫星通信过程中, 由于转发器的非线性, 要求所发射的信号包络趋于恒定, 因此常采用 PSK 调制类型信号, 如 BPSK、QPSK 和 8PSK. 随着时代发展, 通信业务逐步增大, 频谱资源的利用也变得越发紧张, 需采用

更高阶的调制方式来提高频谱利用率, 如 16QAM. 鉴于此, 本文针对卫星中常用的调制类型, BPSK、QPSK、8PSK 以及 16QAM, 进行调制识别与解调联合算法的研究.

传统的信号识别算法中基于信号的幅度、频率和相位的瞬时特征来进行调制分类^[2]的方法受噪声影响大, 在低信噪比条件下算法性能急剧下降. 基于高阶累积分量以及循环谱的方法对噪声相对不敏感, 低信噪比下依旧具有较好的识别性能, 但计算复杂度高, 实时处理能力较差, 且需预估信号的载噪比^[3]. 而信号解调与

信号参数估计精度有关,由于受到通信设备以及信道环境的影响,参数估计的准确度往往难以达到解调要求,最终影响后续信息的获取。

近年来,从事通信领域的研究人员已经开始结合通信系统或者通信信号的本质进行深度学习的研究,如利用卷积神经网络拟合传统通信流程中的匹配滤波器功能,进行调制识别和接收检测^[4]。文献[5]通过构建编码、译码、信道自动编码网络实现了通信信号的发送、接收、同步传输系统。但总体来说,基于信号调制识别以及解调的一体化算法较少,传统方法仍需要大量人工介入。基于此,本文进行探索性研究,将神经网络运用于卫星信号调制识别与解调领域,提出了一种基于循环神经网络的调制识别与解调联合算法。通过实验验证,本文算法调制识别与解调效果均表现良好,具有很好的工程运用前景。

2 信号模型

基带信号波形可以表示为:

$$s(t) = e^{j(2\pi\Delta f t + \phi)} \sum_n a_n g(t - kT) \quad (1)$$

其中 Δf 表示残余载波, ϕ 为载波初相, T 为符号周期, a_n 为符号序列, $g(t)$ 为成型滤波器。

对于 PSK 类信号,有

$$a_n = e^{j(2i+1)\pi/M}, i=0,1,\dots,M-1 \quad (2)$$

对于 QAM 类信号 ($M=4^n, n=2,3,4,\dots$),则有

$$\begin{cases} a_n = I_n + jQ_n \\ I_n, Q_n = 2i - \frac{M}{4} + 1, i=0,1,\dots,\frac{M}{4}-1 \end{cases} \quad (3)$$

采用 DVB-S2 中定义的标准^[6],星座呈圆形的 APSK 调制已应用在实际卫星通信领域,该调制方式克服了频谱资源紧张的问题,且相对于 QAM 信号而言,幅度类型少,降低了预失真校正的复杂性。对于 APSK 信号,有:

$$a_n = r_k \exp\left[j\left(\frac{2\pi}{n_k} i_k + \theta_k\right)\right] \quad (4)$$

其中, r_k 为第 k 个圆周的半径, n_k 为第 k 个圆周的星座点数, i_k 为第 k 个圆周的星座点序号, θ_k 表示第 k 个圆周的初始相位偏移。

实际通信过程中信号由于受到放大器的非线性效应^[7],以及信道环境的作用,接收端信号存在一定的畸变。考虑实际环境的影响,接收端信号可以表示为:

$$r(t) = e^{j\phi(t)} \int_{\tau=0}^{\infty} s(n_{\text{clk}}(t-\tau))h(\tau) d\tau + n_{\text{add}}(t) \quad (5)$$

其中 $e^{j\phi(t)}$ 表示信号相位受时间变化的偏移情况,在一段时间内可假设频偏固定,因此该段时间内可表示为 $e^{j\phi(t)} = e^{j^{2\pi\Delta f t + \theta_0}$, $n_{\text{clk}}(t)$ 表示信号采样出现的定时偏差, $h(t)$ 表示残余信道响, $n_{\text{add}}(t)$ 表示加性高斯白噪声。

3 循环神经网络

循环神经网络(RNN, Recurrent Neural Network)作为一类特殊的人工神经网络,主要用于时间序列处理领域。其利用网络中的循环结构来挖掘样本的时序信息,每个时刻输出层的信息不仅和当前的输入有关,前一时刻的输出同样影响着该时刻的输出。本文采用的循环神经网络模型为长短时记忆(LSTM, Long Short Term Memory)模型^[8]。基本结构如图1所示。

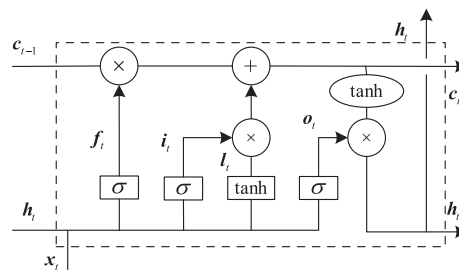


图1 LSTM单元基本结构

在 LSTM 模型中常规的神经元被储存单元代替,每个储存单元包含多个记忆细胞以及三个乘法控制单元:输入门输出门和遗忘门。这三类门分别提供了读、写、重置的功能。在前向计算过程中,输入门控制着当前信息的输入,遗忘门控制着是否重置之前的记忆信息,输出门控制着当前记忆信息的输出。根据图1,网络各状态更新如下:

$$\begin{aligned} f_t &= \sigma(\mathbf{w}^f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}^f) \\ i_t &= \sigma(\mathbf{w}^i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}^i) \\ o_t &= \sigma(\mathbf{w}^o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}^o) \\ l_t &= \tanh(\mathbf{w}^l[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}^l) \\ c_t &= f_t \cdot c_{t-1} + i_t \cdot l_t \\ h_t &= o_t \cdot \tanh(c_t) \end{aligned} \quad (6)$$

其中, f_t, i_t, o_t 分别表示遗忘门,输入门和输出门, l_t 表示当前输入 \mathbf{x}_t 生成的候选数值, c_t 表示隐藏神经元的状态, $[\mathbf{h}_{t-1}, \mathbf{x}_t]$ 表示 $t-1$ 时刻隐藏层的输出和 t 时刻的输入向量。 \mathbf{w}^f 和 \mathbf{b}^f 表示遗忘门的权重矩阵和偏置, \mathbf{w}^i 和 \mathbf{b}^i 表示输入门的权重矩阵和偏置, \mathbf{w}^o 和 \mathbf{b}^o 表示输出门的权重矩阵和偏置, \mathbf{w}^l 和 \mathbf{b}^l 表示当前时刻输入数据生成当前状态的权重矩阵和偏置。

4 调制识别与解调模型的建立与实现

4.1 模型框架

本文通过 TensorFlow 平台来搭建该模型。图2为本文所设计的神经网络架构图,识别模块输出层则采用的是 softmax 激活函数,解调模块输出层采用的为线性激活函数,中间各层的激活函数为 relu 激活函数。

图中虚线表示:在进行解调模块训练时,网络结合

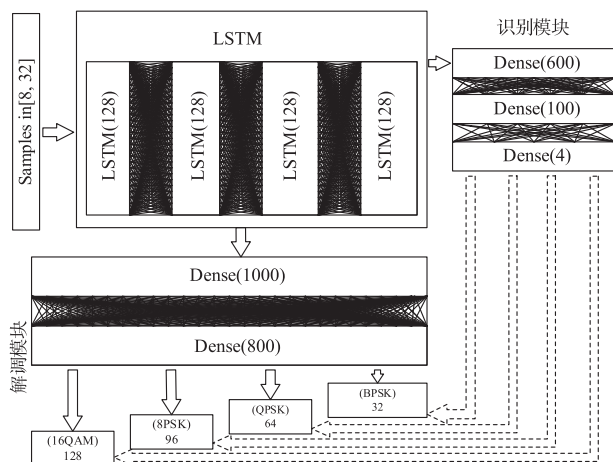


图2 网络架构图

识别模块得出的信息,促进解调模块的训练,具体训练流程将在下节进行说明;当网络训练完成后,目标信号先经过识别模块识别出信号的具体调制类型,根据识别结果,解调模块自动调度其对应的小解调单元完成信号解调.值得说明的是,就开发维护和更新拓展而言,当需对现有的调制识别集中添加新的调制方式时,只需对上述系统进行微调:识别模块最后一层增加相应的节点数,解调模块增加对应的小解调单元数.由于网络结构大体未发生改变,可借鉴预训练^[9]的思想,利用已训练好的网络参数作为新网络的参数初始值,经过简单的再训练即可适应新的调制方式.

4.2 训练样本产生以及网络训练

为了使得样本更具多样性,考虑到实际接收信号存在多方面因素的影响,样本产生过程中人为引入采样相偏、频偏、相偏以及幅度衰减,并通过信道模型来仿真多径、衰落、畸变等.由于本系统需要完成调制识别以及信号解调两部分内容,样本标注过程需标注其对应的调制类型,以及生成该信号的比特数据.信号集利用 Matlab 平台产生.

由于本文需解决信号的调制识别和解调,属于多任务系统,对其训练过程主要分成两个部分:一是对调制分类神经模块进行训练,二是对各解调神经模块进行训练,具体训练方法如图 3.

如图 3 所示,训练过程主要分成两个阶段,首先对调制识别模块进行训练,训练过程中每一训练批次的样本为不同调制方式的信号,当该模块在测试集上的识别性能达到所设定的阈值时,暂时屏蔽该模块的训练,开始进行解调模块的训练.与调制识别模块不同的是,解调模块在每一轮的训练可分成 4 个小批次,每个小批次分别对应着 BPSK, QPSK, 8PSK, 16QAM 的小解调单元的训练,并在网络前向传播过程中计算各个解调单元的解调误码率,与所设定的阈值进行对比.当各

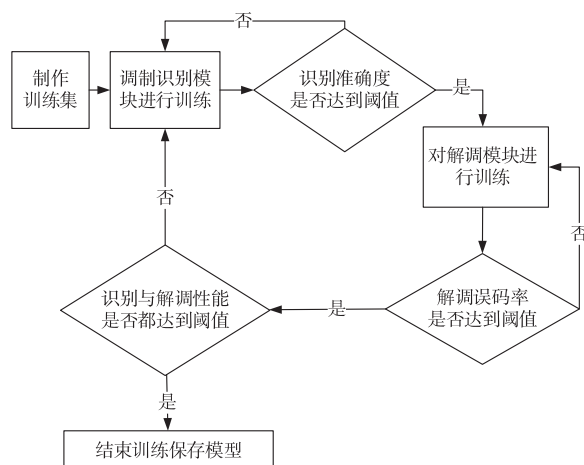


图3 网络训练流程

个小解调单元的解调性能超过阈值时,进行下一步操作,反之继续训练.为保证在进行解调模块训练时,由于循环神经单元参数的改变,调制识别模块的性能严重下降,在解调模块训练完成后对调制识别模块重新进行测试,若各项指标都达到所设定的性能要求时,保存模型;反之,重新回溯到调制识别模块的训练,直到模型达到所设定的性能要求,结束训练.网络优化过程中,采用的是 Adam 优化器进行网络参数的最优求解.本文算法属于多任务系统,不同的模块存在不同的损失函数.对于调制识别模块的训练,选取交叉熵作为损失函数:

$$J_1(\mathbf{w}, \mathbf{b}; \mathbf{x}, \mathbf{y}) = -\sum_i^N (y_i)^T \log(f_1(\mathbf{x}_i; \mathbf{w}, \mathbf{b})) + \lambda_1 \sum \|\mathbf{w}\|^2 \quad (7)$$

其中, \mathbf{y}_i 表示目标信号的实际类别, $f_1(\mathbf{x}_i; \mathbf{w}, \mathbf{b})$ 为调制识别模块的输出, $\lambda_1 \sum \|\mathbf{w}\|^2$ 表示网络系数正则化, λ 为正则化权重,通过正则化网络,可以有效的避免网络出现过拟合现象. N 表示训练批次大小.

对于解调模块的训练,则采用均方误差 (MSE, Mean Squared Error) 作为损失函数,且在设计过程中利用调制识别模块所得信息对目标函数进行优化,最终网络的损失函数为:

$$J_2(\mathbf{w}, \mathbf{b}; \mathbf{x}, \mathbf{m}) = \sum_i^N (m_i - f_2(\mathbf{x}_i; \mathbf{w}, \mathbf{b}))^T \cdot (m_i - f_2(\mathbf{x}_i; \mathbf{w}, \mathbf{b})) p_i + \lambda_2 \sum \|\mathbf{w}\|^2 \quad (8)$$

其中, \mathbf{m}_i 表示真实的比特流数据, $f_2(\mathbf{x}_i; \mathbf{w}, \mathbf{b})$ 表示解调模块的输出值, p_i 表示识别模块对该调制方式识别置信度.通过引入调制识别模块信息对网络训练进行指导,其目的是减少解调训练过程中识别模块结果不理想或是识别错误的样本对解调模块的影响.

5 性能测试与分析

本节对调制识别与解调算法性能进行仿真,待识别调制集为{BPSK, QPSK, 8PSK, 16QAM}. 为了检验对新调制方式的适应性,另添加了一类卫星上常见的调制类型 16APSK,实现方式为 DVB-S2 中定义的标准^[6],由两个同心圆构成,半径之比为 $r_1:r_2=0.4135:1.1289$,内外环星座点数为 $n_1=4, n_2=12$,各环初相为 $\theta_1=\pi/n_1, \theta_2=\pi/n_2$. 训练样本如不做特别说明,仿真条件为:符号随机均匀产生且统计独立,采用均方根余弦成形,滚降系数在 0.1~0.4 之间随机选取,信号质量 (E_b/N_0) 在 0dB~20dB 随机产生,过采样数为 4.

5.1 调制识别与解调性能测试

本节对文中提出的调制识别算法和解调算法进行仿真实验,测试调制识别算法时,信噪比范围为 0dB~20dB,每个信噪比下进行 1000 次蒙特卡洛仿真. 如图 4 所示,为本文指定的 4 种调制信号随信噪比变化的识别性能. 其中,图中低质量信号是指信号存在频偏、定时偏差、多径影响,其具体参数为相对符号速率的归一化载频误差在 $[-0.01, 0.01]$ 内随机取值,定时偏差在 $[-T_{\text{samp}}/4, T_{\text{samp}}/4]$ 内随机取值,其中 T_{samp} 为符号周期. 多径数目为 0 至 5 条,各径能量距主径时间成指数衰减. 如不做说明下文所述低质量信号生成条件如上. 可以看出在低信噪比的情况下,本文算法性能明显由于传统算法. 传统算法的分类性能在很大程度上取决于所提取特征的固有分类能力,存在一定的性能瓶颈. 而本文设计的基于循环神经网络的分类模型,通过直接对原始时间序列进行深层解析,规避了传统算法中人工设计特征所带来的不足,在复杂信道环境下鲁棒性较差.




图4 不同信噪比下的识别概率

解调算法测试时,每个信噪比下对 10000 比特流生成的波形信号进行解调. 如图 5 所示,本文算法接近理论值(由于误码率为仿真值,其数值可能具有浮动性),

且在信号存在定时偏差、频偏以及多径时仍能取得可观的性能. 本文所搭建深度学习模型,克服了传统方法对信号符号数的要求,在信号符号数较少的情况下,通过对样本的学习,解调性能仍能接近理论值,十分适合运用于短突发类型信号.




图5 各调制方式解调性能

5.2 新调制方式适应性测试

本节主要验证本文所涉及的模型的另一创新之处:易扩展性. 相对于传统算法在需添加新的调制方式进行调制识别时,开发维护和更新拓展复杂度大、处理步骤繁多导致综合检测概率低等缺点,该模型则能很好地对新调制方式进行扩展. 本实验将基于 DVB-S2 标准所定义的 16APSK,进行适应性仿真实验,首先按照上文算法流程对网络进行微调并再训练. 最终实验结果如图 6 和图 7 所示.




图6 预训练后模型的识别率

图 6 为网络经预训练完成后对 5 类样本的准确率,可以看出,基于预训练的网络在经过一定的适应性训练后,最终网络对所有调制方式的识别性能都能达到较为理想的性能. 解调性能如图 7,在低信噪比、定时偏差以及多径条件下以及表现优异. 最终有效的验证了

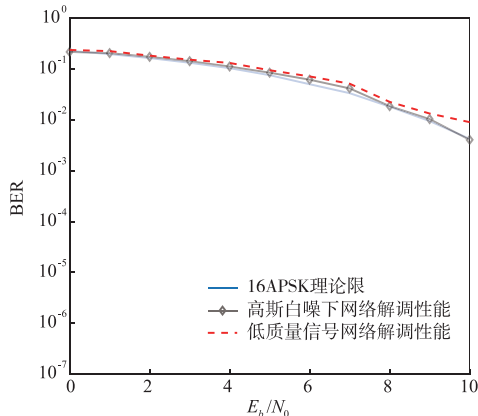


图7 预训练后模型对16APSK的解调性能

本文算法的易扩展性,具有很强的工程应用前景.

5.3 网络参数对性能的影响

本节主要测试网络参数对性能的影响,主要从循环神经的参数设置进行考虑.不同的参数设置会导致不同的模型性能,本文模型参数的设置主要是通过实践测试所得出的,如图8所示,为LSTM参数设置后的调制识别的准确率,主要从层数以及每层循环单元的个数两个层面来考虑.从最终结果中可以看出,网络过浅,最终识别性能并不理想;而过深的网络,也并不能带来更好地模型性能.最终本文选用每层循环单元个数为128,深度为4的结构.




图8 循环单元参数对网络性能的影响

6 结论

深度学习作为人工智能的前沿技术,正逐步运用于实际生活中各项领域.本文结合深度学习技术的优势,将其运用到通信信号调制识别与解调领域,提出了一种基于循环神经网络的调制分类与解调算法.该方法克服了传统方法对信号先验信息依赖强、频偏容忍力弱以及需要人为阈值设定的不足.利用深度学习技术的自学习能力对信号进行特征提取,并创新的将调制识别与解调相结合,使得整个模型更加趋于认知化,

人工干预少,具有很强的应用价值.且相比于传统方法,本文模型在解调过程不需利用大量数据进行统计分析得出相关参数,适合短突发信号.值得说明的是,当需要对新的调制方式进行识别时,只需对原有训练好的模型进行微调训练,较传统方法需重新设定规则更加具有实用价值.

参考文献

- [1] 张俊林,王彬,汪洋,刘明骞.一种 α 稳定分布噪声下 OFDM 信号调制识别与参数估计算法[J].电子学报,2018,46(6):1390-1396.
ZHANG Jun-lin, WANG Bin, WANG Yang, LIU Ming-qian. An algorithm for recognition and parameters estimation of OFDM in alpha stable distribution noise[J]. Acta Electronica Sinica, 2018, 46(6): 1390-1396. (in Chinese)
- [2] 廖灿辉,涂世龙,万坚.一种抗频偏的卫星幅相调制信号识别算法[J].电子与信息学报,2014,36(02):346-352.
Liao Can-hui, Tu Shi-long, Wan Jian. An anti-frequency-offset algorithm for modulation recognition of satellite amplitude-phase modulated signals[J]. Journal of Electronics & Information Technology, 2014, 36(02): 346-352. (in Chinese)
- [3] 孟宪波,鲍长春.基于最小控制 GARCH 模型的噪声估计算法[J].电子学报,2016,44(3):747-752.
MENG Xiao-bo, BAO Chang-chun. Noise estimate algorithm based on minima controlled GARCH model[J]. Acta Electronica Sinica, 2016, 44(3): 747-752. (in Chinese)
- [4] OShea T J, Corgan J, Clancy T C. Unsupervised representation learning of structured radio communication signals [A]. 2016 First International Workshop on Sensing, Processing and Learning for Intelligent Machines [C]. Aalborg, Denmark; IEEE, 2016. 1-5.
- [5] OShea T J, Karra K, Clancy T C. Learning to communicate: channel auto-encoders, domain specific regularizes, and attention [A]. 2016 IEEE International Symposium on Signal Processing and Information Technology [C]. Limassol, Cyprus; IEEE, 2016. 223-228.
- [6] ETSI TR 102 376 v1.1.1, Digital Video Broadcasting (DVB) User Guidelines for the Second Generation System for Broadcasting, Interactive Services, News Gathering and Other Broadband Satellite Applications (DVB-S2) [S].
- [7] 杨霖,何向东,丁长文. OFDM 系统中基于限幅和压缩感知的非线性失真补偿算法[J].电子学报,2016,44(9):2051-2056.
YANG Lin, HE Xiang-dong, DING Chang-wen. Compensation method for nonlinear distortion based on clipping and compressive sensing in OFDM system[J]. Acta Electronica

Sinica, 2016, 44(9): 2051 – 2056. (in Chinese)

- [8] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 – 1780.
- [9] Vincent P, Larochelle H, Lajoie I, et al. Stackeddenoising

autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371 – 3408.


作者简介



查 雄 男, 1995 年出生, 江西九江人. 现为战略支援部队信息工程大学研究生, 主要研究方向为智能信号处理.
E-mail: mici0928@163.com



彭 华 男, 1973 年出生, 江西萍乡人. 现为战略支援部队信息工程大学教授、博士生导师, 主要研究方向为软件无线电、通信信号处理.



秦 鑫 女, 1994 年出生, 重庆人. 现为战略支援部队信息工程大学研究生, 主要研究方向为雷达信号处理.

李天昀 男, 1979 年出生, 江西萍乡人. 现为战略支援部队信息工程大学副教授, 主要研究方向为通信信号处理, 软件无线电.

李 广 男, 1996 年出生, 湖南永州人. 现为战略支援部队信息工程大学研究生, 主要研究方向为通信信号处理.