

一种基于并行覆盖前馈优先神经网络的说话人识别方法^{*}

姚 潇¹ 武 妍¹ 王守觉²

(同济大学计算机科学与工程系 上海 200092)¹ (中国科学院半导体研究所神经网络实验室 北京 100083)²

摘 要 为实现对说话人特征空间多聚类区的有效识别,提出一种基于并行覆盖前馈优先神经网络(PCPONN)的说话人识别方法。该方法以 LBG 算法生成每个说话人特征空间初始的聚类中心,对本类样本按聚类中心分类后,用前馈优先神经网络(PONN)对每个聚类区进行并行覆盖。相关实验证明,PCPONN 符合说话人特征空间点的分布特点,得到更好的稳定性和更高的识别率。

关键词 说话人识别,并行前馈优先神经网络(PCPONN),倒谱,聚类区

Research on Speaker Recognition Based on the Parallel Coverage of Priority Ordered Neural Network

YAO Xiao¹ WU Yan¹ WANG Shou-jue²

(Institute of Semiconductors and Information Technology, Tongji University, Shanghai 20092, China)¹

(Lab of Artificial Neural Networks, Institute of Semiconductors, CAS, Beijing 100083, China)²

Abstract In order to realize the effective coverage of multiple clusters area in the speaker's feature space, a method of parallel coverage of priority ordered neural network (PCPONN) is put forward. Based on the initial clusters center generated by the LBG in every speaker's feature space, every sample can be classified, so every clusters area can be parallel covered by the PONN. The relative experiment results show PCPONN is consistent with the distribution of speaker's feature point, so has better stability and higher correct recognition.

Keywords Speak recognition, Parallel coverage of priority ordered neural network(PCPONN), Cepstrum, Clusters area

1 引言

说话人识别(Speaker Recognition)是指通过对说话人语音信号的特征分析与参数提取,从而能对说话人身份进行辨认和确认。其研究起始于 19 世纪 60 年代,到目前为止该领域的研究取得了突飞猛进的发展。目前,已有许多方法应用于说话人识别,如基于动态时间规整算法(Dynamic Time Warpping, DTW)的模板匹配法和基于隐马尔可夫模型(Hidden Markov Model, HMM)的概率统计的方法^[1],但它们的缺点是计算量大,训练时间长。70 年代后,高斯混合模型(Gaussian Mixture Model, GMM)^[2]和矢量量化(Vector Quantization VQ)方法^[3]在说话人识别中得到了广泛应用,逐渐成为与文本无关的说话人识别系统的主要方法之一。应用 VQ 建立识别模型,无须像 DTW 那样需要进行时间规整,在训练时计算量、运算复杂度及训练时间开销方面 VQ 方法要优于传统的语音识别方法 HMM,但其缺点在于只描述了各个聚类中心,是对帧特征在特征空间的统计特性的不完全描述。

考虑到说话人语音信号在高维空间的分布特点,本文在用传统 LBG(Linde Buzo Gray)生成初始聚类中心的前提下,以仿生模式识别为基础^[4],用前馈优先排序神经网络(PONN)^[5]对高维空间的点进行覆盖。由于每个说话人提取的特征矢量在高维空间中集聚于几个不同的区域,每个聚类区都包括许多相似的特征矢量,故对每个区域生成相同优先级的神经元,逐级对空间点进行并行覆盖,构造出进行并行覆

盖的前馈优先排序神经网络(PCPONN),从而达到识别目的,在实验中取得了比较理想的效果。

2 前馈优先排序神经网络基础理论

2.1 网络基本模型的定义

优先排序网络的基本思想是空间类别的划分具有层次特征(基本符合人类认知过程),大类识别由小类逐层判别构成。概念体现到网络层结构,如图 1 所示。




图 1 PONN 网络层次结构

2.2 网络构造基本原理

对于神经元 $\psi_{i,j}^k$,规定单个神经元 $\psi_{i,j}^k$ 在高维特征空间中是有限空间区域覆盖,同时为了分析方便,认为在高维空间中其覆盖区域是各向同性,近邻覆盖空间采用欧式度量空间,通过空间特征点与空间支撑点的距离比较进行测度。

$$\rho(\psi_{i,j}^k) = \sqrt{\sum_{l=1}^n (X_l - X_{l_0})^2} \quad (1)$$

当 $\rho(\psi_{i,j}^k)$ 测度小于阈值 Γ_0 , $\Gamma_0 \in R$ (阈值由支撑点与异类

^{*}国家自然科学基金资助项目(60475019)。姚 潇 硕士研究生,主要研究方向为生物特征识别、人工神经网络;武 妍 教授,博士,博士生导师,主要研究方向为神经网络、模式识别、图像处理;王守觉 中国科学院院士,主要从事神经网络、仿生模式识别理论与方法的研究。

样本最近距离确定),则认为在区域覆盖范围内;反之,则表示在覆盖区域之外,即不被此神经元 $\psi_{i,j}^k$ 覆盖,形式化描述如下。

$$F(\rho) = \begin{cases} 1, \rho < \Gamma_0 \\ 0, \text{其它} \end{cases} \quad (2)$$

网络构造基本原理:网络训练依据训练样本本身的特征属性,起始阶段网络内部的层次为空,即 $k=0$ (不同于传统网络需预先确定神经元数目);随着训练样本进入网络,网络层 k 逐渐增大,神经元数不断增多,构成层内神经元 $\{\psi_i^k\}$ 集合,要求同层神经元在高维空间覆盖区域不可重叠。

网络识别基本原理:网络接受待判别数据输入 $x \in R^n$,各层神经元输出响应序列 O_k ,定义判别:

$$Y_i := \{i | i = \{0 \text{ 或 } q_i = \{\min(k) \& \{O_k > 1 \rightarrow p\}\}\} \} \quad (3)$$

通过 Y_i 对待识别样本 $x \in R^n$ 进行类别划分,

$$Y_i = \begin{cases} \text{类别 } i, i > 0 \\ \text{拒绝}, i = 0 \end{cases} \quad (4)$$

从网络对类别的类型识别来看,PCPNN 很好地描述了异类样本的拒识情况,优于传统网络对于不“认识”样本的乱识问题。

3 并行覆盖前馈优先排序神经网络的基本理论及构造算法

3.1 PCPNN 空间的构造

在现实世界的模式识别中,每一类样本的特征向量在特征空间中并不一定都聚集在一起,而是存在多个不同的聚集区域(后面称为子聚类区),使不同类样本的类间相似性超过了同类样本的类内相似性,如果对每一类的统一覆盖,可能会产生误识率,得不到最优的效果。对此可以对每类的特征空间进一步细化,按照其特征空间分布特点来构造神经网络。

本文提出 PCPNN 的主要思想就是基于每类特征空间中的多个子聚类区,由 LBG 算法产生初始的子聚类中心,然后对每个子聚类中心进行神经元覆盖,并同时赋予相同且最高的优先级别,将其他未覆盖的点依据最小欧式距离依次归类至其所属的子聚类中心,最后对每个子聚类区的其他未覆盖的特征点进行并行的 PONN 覆盖。

第一步:用 LBG 算法获取初始聚类中心

由于每类中多个子聚集区的存在,可以用传统的码书设计算法(LBG)大致找到这些聚类区的初始子聚类中心,设有 P 类, $W = \{w_1, w_2, \dots, w_p\}$, 对于第 l 类,特征向量为 $X = \{x_1, x_2, \dots, x_n, x \in R\}$, 经过 LBG 得到 m 个子聚类中心 $C = \{c_1, c_2, \dots, c_m\}$ 。

第二步:将样本按子聚类区分类

(1)分别计算每个特征向量 x_i 到 $C = \{c_1, c_2, \dots, c_m\}$ 的距离 $\rho(x_i, c_j) i=1, \dots, n, j=1, \dots, m$;

(2)由 $\min \rho(x_i, c_j)$ 求出 x_i 到各个子聚类中心 c_j 的最短距离;

(3)将每个 x_i 归并到 c_j 的类中,从而将样本点聚成 m 个子聚类区 $S = \{s_1, s_2, \dots, s_m\}$ 。

第三步:对每个聚类区进行 PONN 覆盖,构造并行神经元。

步骤 1 由于使用 LBG 算法所得的子聚类中心只是初始值,并不能完全描述这一子聚类区,其目的在于初始分类,故在 PONN 覆盖前,可对每个子聚类区的特征点进行均值处理,得到新的中心值为(5)式,并设定优先级 $pri=1, k=1$ 。

$$c_{jk}^{pri} = \frac{1}{\text{card}(s_j)} \sum_{i=1}^{\text{card}(s_j)} x_i, x_i \in s_j, j=1, \dots, m \quad (5)$$

步骤 2 对于第 j 个子聚类区重新选择子聚类中心 c_{jk}^{pri} 为第一个支撑点, c_{jk}^{pri} 表示第 j 个覆盖区优先级为 pri 的第 k 个神经元支撑点,用神经元 ψ_{jk}^{pri} 对其进行高维空间的覆盖 s_j , ψ_{jk}^{pri} 表示第 j 个覆盖区优先级为 pri 的第 k 个神经元。由于第一个支撑点处于子聚类区的中心位置,周围特征点分布相对密集,故此时可以取较大的阈值 Thr_{pri}, Thr_{pri} 由实验获得,覆盖得到的 s_j 子集合为 O_{jk} 。

步骤 3 从 s_j 中去掉 O_{jk} ,产生剩余的样本集,转向步骤 4

$$s_j = s_j \setminus O_{jk} j=1 \dots m \quad (6)$$

步骤 4 对于剩余样本,继续由式(8)求得均值中心作为支撑点,由于剩余的样本点在子聚类区的特征空间相对处于边缘,因此可改用较小的阈值

$$Thr_{pri} = (1 - 0.1 * pri) Thr_{pri-1} \quad (7)$$

用神经元 ψ_{jk}^{pri} 以式(10)所定阈值进行覆盖,得到子集合 O_{jk} ,这时如果 $O_{jk} \neq \phi$,则转向步骤 5,但若 $O_{jk} = \phi$,说明剩余特征点并未集中,所以用神经元 ψ_{jk}^{pri} 进行覆盖后,用式(11)取支撑点,对此支撑点继续进行高维空间覆盖,直到 $O_{jk} \neq \phi$,转向步骤 5。

$$c_{jk}^{pri} = \{x | \min \rho(x, c_j), x \in s_j\} \quad (8)$$

步骤 5 用步骤 3,4 并行处理其他的子聚类区,并分别设置此时的优先级 Thr 为同一级别,此后 $pri = pri + 1$,转向步骤 6。

步骤 6 不断循环步骤 3-5,直到所有子聚类区的每个特征点都被覆盖。

步骤 7 重复以上所有步骤,直到构造完所有类别的神经网络覆盖空间。

这样,每一类样本的构造空间中就有相同优先级的 k 个神经元,对于每个神经元外的其它特征点可进行并行覆盖,由于覆盖区中特征点分布离散度有差异,故每个 PCPNN 所得的神经元个数也不同,离散度小的聚类区,PCPNN 神经元数量少。反之,则须用多个神经元才能将其覆盖,全部覆盖后就构造出了整个区域的神经网络。

3.2 识别算法

提取特征得到的测试样本集为 $Y = \{y_1, y_2, \dots, y_i\}$,对于每个测试样本,在每类训练好的类别特征空间中并行地抽取所有子聚类区 $pri=1$ 的 a 个神经元 $\psi_{i,k}^1$,计算 y_i 到每个神经元支撑点的距离:

$$\rho_{i,k}^1 = \|y_i - c_{i,k}^1\| \quad (9)$$

则待识别样本点到第 l 类的高维空间覆盖区的距离为:

$$\rho_l = \min_j \min_k \rho_{i,k}^l \quad l=1, \dots, P \quad (10)$$

如果所得 ρ_l 满足

$$\rho_l \leq Thr_l \quad (11)$$

则将 y_i 的类别归为第 l 类,识别结束。否则继续增大 pri ,计算最小距离,直到满足(14)式的要求为止,如果都不满足,则表示是个新类别样本,不属于任何已训练类别,应给予拒识,这也就克服了传统模式识别对于“不认识”的样本强行“乱识”的缺点。

4 PCPNN 在说话人识别中的应用

4.1 MFCC 特征提取

对于说话人语音信号的特征提取,早期是用语音信号的

长期平均值来表示。但多年的实验证明,短时语音的倒谱系数^[6]更能有效地描写声道和听觉特征,对于说话人识别有良好的效果。基于人耳听觉特性的 Mel 频率尺度的值时对应于实际频率的对数分布关系,两者关系可表现为:

$$Mel(f) = 2.595 \lg(1 + f/700) \quad (12)$$

首先,将信号进行短时傅立叶变换得到其频谱。

其次,求频谱幅度的平方得到能量谱。在频域上按照关键带的划分构造一组三角形滤波器,带通滤波器组的中心频率按 Mel 频率均匀排列,每个滤波器三角形的两个底点是相邻滤波器的中心,相邻滤波器过渡带的频率响应之和为 1,用三角形滤波器组在频域对能量谱进行带通滤波,滤波后得 M 个滤波器的输出: $X(k), k=1, 2, 3, \dots, M$

最后,将滤波器组的输出取对数,然后对它做离散余弦变换(DCT)得到 MFCC

$$MFCC_n = \sum_{k=1}^M \ln X(k) \cos \left[\frac{\pi(k-0.5)n}{M} \right] \quad n=1, 2, \dots, L \quad (13)$$

这里 MFCC 的系数个数 n 通常取小于等于 M , 而根据 MFCC 各个分量对于说话认识的贡献不同,可舍去前两个特征分量,保留第 3-14 个 MFCC 分量,能取得更好的实验效果。

4.2 样本压缩

由以上得到特征向量集中,由于采样频率的增大,使得样本集规模十分巨大,直接训练会在很大程度上增加时间和空间复杂度,因此要适当地进行样本压缩^[7]。设连续相邻的两个特征向量为 C_i 和 C_{i+1} , 计算两者之间的高维空间夹角:

$$\theta_j = \arccos \left(\frac{C_i \cdot C_{i+1}}{|C_i| \cdot |C_{i+1}|} \right) \quad (14)$$

当夹角小于统计实验数据 0.13rad 时,则删去 C_i 或 C_{i+1} 中的一个,直到相邻向量间的夹角都大于或等于 0.13rad。

4.3 构造特征空间识别覆盖区

跟其它生物特征识别不同,每个说话人所对应的特征向量并不是完全聚集在一起的,而是聚集在几个不同的区域的,它代表了每个说话人的特征。如不同的说话人对于同一个音素的发音存在着很大的相似性,从而从发音特征来说,其特性向量在空间中一定会产生多个不同的子聚类区。对所有说话人的每类样本进行学习,采用上述提出的并行的优先级排序神经网络覆盖方法构造每个说话人的数字语音模型。

4.4 实验结果与分析

为了验证本文所提出的 PCPONN 算法的有效性,实验中我们使用了含 15 个人的语音数据库,10 个男性,5 个女性,将其中 13 个人进行训练,另外一个男性和一个女性仅做测试样本的拒识分析。每人语音长度为 45 秒,采样频率为 11025Hz,采用 16bit 量化,经过消除寂静音后,选取帧长为 256,帧移为 80,每帧提取 14 个 MFCC 特征后,去掉前两个对说话人识别有影响的系数,并提取动态的差分倒谱参数,一共 20 维的特征向量^[8],然后将每连续 8 帧进行合并,故每个完整的特征向量为 160 维。

实验分别取 Thr 为 30, 40, 50, 60 不同的阈值进行实验,并随机取 20 秒, 25 秒, 30 秒作为训练样本,参加训练 13 人的余下 10 秒作为测试样本,结果如表 1。

表 1 不同训练时间在不同阈值下的正确识别率

	Thr=30	Thr=40	Thr=50	Thr=60
T=20s	68.3%	83.5%	91.8%	93.0%
T=25s	78.8%	88.2%	93.5%	94.1%
T=30s	87.1%	93.9%	97.2%	97.7%

从以上数据可以看出来,训练样本越多,空间覆盖面积就越大,正确识别率也就越高,由于空间覆盖理论是基于特征空间同类样本的连续性,扩大了可参考样本点的数量,故尽管在小样本的情况下(如 $T=20s$),仍然可以获得较为可观的识别率。而随着阈值的不断增大,落入覆盖区内的样本越来越多,正确识别率呈上升趋势,但到一定的程度,增大阈值并没有显著的提高正确识别率,如阈值到 50 和 60 时,这是因为基于阈值的增大,所有支撑点附近的样本点都已经被覆盖,所以继续增大阈值已经没有太大意义,而被包括进来的即包括正确识别的样本点,也包括错误归类的样本点,这样会对误识率和拒识率产生影响(如表 2)。

将全部的 15 人的测试样本进行误识和拒识分析,观察其结果。

表 2 不同阈值下的误识拒识分析($T=25s$)

	Thr=30	Thr=40	Thr=50	Thr=60
误识率	2.5%	3.2%	6.6%	8.1%
错误拒绝率	17.2%	9.9%	3.1%	1.6%
正确拒识率	12.0%	10.7%	9.3%	9.3%

由表 2 可以看出,随着阈值的增大,误识率会有提高,而错误拒绝率和正确拒识率会相应地下降,与表 1 对应起来,当阈值增大时,许多样本点都逐渐被包括到覆盖区域内,导致拒识率的下降,而包括进来的样本点如果正确归类,则增加了正确识别率;反之,就会提高误识率(阈值为 60 时已经有 8.1%)。由于第 15 个人没有参加训练,因此算法始终保持相当的正确拒识率,考虑到算法的安全性,一定的错误拒绝率也是非常必要的,而阈值过大时,错误拒绝率几乎为零(1.6%),所以为了不提高误识率,一般不能将阈值设置过大。但如果设置过小,算法退化为简单的最近邻法。由于阈值增大到 40 时,并没有显著提高误识率,而且有较高的识别率,故本文将阈值选择设置为 40。

实验中分别用 GMM, VQ 进行实验比较,如表 3, GMM 中取高斯分量个数为 16, 同样在 VQ 中取 16 的码本长度,比较其正确识别率以及误识率。

表 3 不同识别算法比较

	GMM		VQ		PONN		PCPONN	
	识别率	误识率	识别率	误识率	识别率	误识率	识别率	误识率
T=20s	73.8%	17.3%	75.4%	16.2%	80.1%	11.6%	83.5%	5.7%
T=25s	77.1%	11.5%	81.5%	12.9%	85.3%	9.8%	88.2%	3.2%
T=30s	80.3%	10.2%	84.2%	9.7%	89.7%	8.0%	93.9%	2.6%

从表 3 看出,基于空间覆盖的 PCPONN 在小样本情况下要明显优于基于空间划分的传统模式识别,而在误识率方面也体现出巨大的优势,对于某些异样的样本,PCPONN 选择拒绝,而不是乱识,勉强地将其划分到某一错误的分类中,这样保证了算法的实用性和安全性。相对于基于直接覆盖的 PONN, PCPONN 体现出较高的正确识别率和较低的误识率,这是由于在语音信号中,不同的说话人发同一个音时存在比较大的相似性,例如语音中的清音,在高维空间中其两者之间的距离可能小于不同说话人之间的平均距离,所以如果统一将其覆盖,可能其中会包括很多其他说话人的样本点,导致误识率增加。这也说明 PCPONN 的多聚类区的并行覆盖算法,更加符合说话人识别的特点。

结束语 并行覆盖的 PONN(PCPONN)算法利用 LBG 算法,生成说话人多个聚类区的初始聚类中心,而后对这些聚

类区进行并行的 PORN 空间覆盖。通过以上实验证明,此方法更加符合每个说话人的特征向量在高维空间中的分布特点,取得了比较令人满意的实验效果。同时,降低 LBG 的时间复杂性,选择更加复杂的神经元结构,将成为今后的研究方向。

参 考 文 献

[1] Zhang Y B, Zhou J. Audio Segmentation Based on Multi-scale Audio Classification[C]//Proc. of IEEE ICASSP. 2004; 349-352
 [2] Reynolds D A. Speaker identification and verification using Gaussian mixture. Speech Communication, 1995, 17: 19-108
 [3] Zhang Xinyi. Optimum Vector Quantization Codebook Design for Speaker Recognition[C]//Proc. of the ICSP. 2004; 1397-1402
 [4] 王守觉. 仿生模式识别(拓扑模式识别)——一种模式识别新模

型的理论与应用[J]. 电子学报, 2002, 30(10): 1417-1420

[5] Wang Showjue. Priority Ordered Neural Networks with Better Similarity to Human Knowledge Representation[J]. Chinese Journal of Electronics, 1999, 8(1): 1-4
 [6] Zolnay A, Schlüter R, Ney H. Acoustic Feature Combination for Robust Speech Recognition// IEEE Int. Conf. on Acoustics, Speech, and Signal Processing. Philadelphia, PA, March 2005
 [7] 王守觉, 潘晓霞, 徐春燕, 等. 一种基于高维空间覆盖动态搜索方法的非特定人连续数字语音识别的研究. 电子学报, 2005, 10: 1790-1793
 [8] Reynolds D A. Experimental evaluation of features for robust speaker identification pl. IEEE Trans. Speech and Audio Proc. , 1994, 10(2): 639-643

(上接第 94 页)

设作战单元 A 的报文到达为参数为 λ_A 的泊松过程, 服务率为 μ_A , 由时隙分配方法可知, 作战单元的发送时隙在一个时元周期内是均匀分布的, 每隔一个固定时间发送一个报文, 故作战单元 A 的服务时间为定长分布。因此, 可用 M/D/1 排队模型^[5] 求解时间延迟。令 $\rho_A = \frac{\lambda_A}{\mu_A}$, 记 W_A 为报文的平均延迟时间, 可得:

$$W_A = \frac{1}{\mu_A} + \frac{\rho_A}{2\mu_A(1-\rho_A)} \quad (1)$$

作为指挥、控制、通信中心的预警机, 平均每秒钟生成约 17 报文。设其时隙分配参数为 A-1-14, 则在一个时元周期中, 该预警机总共有 16384 个发送时隙, 一个发送周期为 6τ , 即对报文的的服务率为 21.3。由式(1)可得该预警机的报文平均延迟时间为 0.138 秒。

图 5 给出了取定服务率时, 报文的平均延迟时间随报文到达率的变化情况, 服务率取定(21.3)时, 随着报文到达率的提高, 预警机的信息传输延迟也逐渐增大, 报文到达率为 17 时, 时间延迟约为 0.139 秒, 当报文到达率接近于系统的服务率时, 时间延迟急剧增大。




图 5 报文的平均延迟时间随报文到达率的变化情况




图 6 报文的平均延迟时间随服务率的变化情况

图 6 给出了报文到达率取定时, 报文的平均延迟时间随服务率的变化情况, 报文到达率取定(17)时, 预警机的信息传输延迟随着系统服务率的提高而减小, 服务率为 21.3 时, 时间延迟为 0.138 秒, 而当报文服务率下降接近于报文到达率时, 时间延迟急剧增大。

由以上分析可知, JTIDS 报文的传输延迟主要取决于发送站点的报文到达率和服务率, 由于报文的生成率主要取决于实际应用背景, 故要减小时间延迟, 必须提高站点的服务率, 即分配给发送站点尽量多的时隙, 但一个作战单元时隙分

配过多, 会使 JTIDS 容纳的作战单元个数减少。在 JTIDS 中, 需要传输 256 种报文, 不同报文的到达率不同, 对时间延迟的要求也不同。例如对于执行远程拦截任务的战斗机, 在 12.8 分的时元内, 只需要用 1 个时隙来更新发射器位置和状态信息; 而对于传输目标航迹信息的报文, 则希望有较多的发送时隙, 从而有较短的发送周期, 能够较快地更新目标的航迹信息。但是针对此类报文的时隙分配也不是越多越好, 时隙分配的数量要考虑雷达的探测周期, 如果报文发送周期比雷达的一个探测周期小得多, 则可能造成两个相邻的航迹信息报文传达了同一个航迹信息, 造成了时隙资源的浪费。因此, 需要综合考虑作战单元所承担的任务、发送报文的类别, 以及该报文到达率、报文对时间延迟的要求等因素, 确定分配一个作战单元的时隙个数, 将报文的时间延迟控制在可接受的范围内前提下, 尽量少地占用时隙资源, 容纳较多作战单元。

结束语 本文分析了数据链系统中两点之间直接信息传输、中继信息传输、跨数据链信息传输这三种情况的信息传输过程。给出了利用排队论分析数据链系统信息传输时间延迟的一般流程; 最后分析了美军 JTIDS 中两点之间直接信息传输的时间延迟。本文的分析过程假设信息传输过程是理想的, 即不会出现报文丢失的情况, 接收站不需要发送确认信息。没有考虑报文优先级、报文长度、时隙大小、装备可靠性等因素对报文传输时间延迟的影响。在实际求解过程中, 考虑的影响因素越多, 越难应用排队论模型求出一个解析解。下一步工作是: 建立数据链系统的仿真平台, 以信息传输延迟的各种影响因素为约束, 仿真求解数据链系统的信息传输延迟, 并进行系统优化。

参 考 文 献

[1] JTIDS(Joint Tactical Information Distribution System)-Link 16 [J/OL]2003. 11
 [2] 孙义明, 杨丽萍. 信息化战争中的战术数据链[M]. 北京: 北京邮电大学出版社, 2005
 [3] 陈春明, 王可人. 基于 OPNET 的 JTIDS 网络仿真平台设计[J]. 舰船电子工程, 2006, 25(6): 107-110
 [4] 邢智, 戴浩. 基于 OPNET 的 Link-16 数据链建模与仿真[J]. 军事运筹与系统工程, 2005, 19(1): 62-66
 [5] 华兴. 排队论与随机服务系统[M]. 上海: 上海翻译出版公司, 1987