

# 基于深度神经网络的胎儿体重预测

李 昆<sup>1</sup> 柴玉梅<sup>1</sup> 赵红领<sup>1,2</sup> 赵悦淑<sup>2,3</sup> 南晓斐<sup>1</sup>

(郑州大学信息工程学院 郑州 450000)<sup>1</sup>

(郑州大学互联网医疗与健康服务协同创新中心 郑州 450000)<sup>2</sup>

(郑州大学第三附属医院 郑州 450000)<sup>3</sup>

**摘 要** 由于胎儿体重是反映胎儿生长发育情况、宫内异常妊娠情况的重要指标,因此,胎儿的估重是医生对产妇进行临床处理的一个重要依据。传统胎儿体重预测模型的构建依赖于医学知识与生理参数选择,因此构建过程不易进行复制与推广。针对这些问题,提出一种使用深度神经网络来构建胎儿体重预测模型的方法,同时介绍了从电子病历中提取相关参数的过程,以及针对数据缺失值的补全策略。实验表明,基于深度神经网络的胎儿体重预测模型优于公式预测方法与基于传统人工神经网络的模型,且提出的缺失值补全策略能够强化模型的训练,进而提高预测的准确度。最后,基于深度神经网络的胎儿体重预测模型有很强的泛化能力与通用性,为不同地区、不同医院建立个性化的预测模型提供了可行方法。

**关键词** 胎儿体重,预测模型,深度神经网络

中图分类号 TP391 文献标识码 A

## Estimation of Fetal Weight Based on Deep Neural Network

LI Kun<sup>1</sup> CHAI Yu-mei<sup>1</sup> ZHAO Hong-ling<sup>1,2</sup> ZHAO Yue-shu<sup>2,3</sup> NAN Xiao-fei<sup>1</sup>

(School of Information Engineering, Zhengzhou University, Zhengzhou 450000, China)<sup>1</sup>

(Collaborative Innovation Center for Internet Healthcare, Zhengzhou University, Zhengzhou 450000, China)<sup>2</sup>

(The Third Affiliated Hospital of Zhengzhou University, Zhengzhou 450000, China)<sup>3</sup>

**Abstract** Fetal weight is an important indicator which reflects the fetus's growth and development status, so the estimation of fetal weight becomes a crucial foundation in obstetrical decision. Most traditional fetal weight prediction models are based on medical knowledge and feature selection, which are leading to the hard repetition and promotion of the model building process. For these problems, we proposed a deep neural network structure for building fetal weight prediction model, and introduced the process in which parameters are extracted from electronic health records and the filling strategies for missing values. The experimental results show the deep neural network based prediction model outperforms traditional methods, and the filling strategy can reinforce the training of the model and improve the accuracy. Finally, the generalization ability and universality of the deep neural network model can help different areas and hospitals to build personalized fetal weight prediction model.

**Keywords** Fetal weight, Prediction model, Deep neural network

## 1 引言

在妇产科学中,对胎儿体重进行预测具有非常重要的意义。胎儿的体重能够直观地展现出胎儿在子宫内的发育情况,进而辅助医务人员对产妇的生产方式做出决策。随着经济水平的提高与医疗技术的进步,一些新的问题也突显出来:1)新生儿的平均体重逐渐增加,巨大儿的发病率也在逐年上升,占新生儿的 5.62%~6.49%,随之而来的就是难产率和剖宫产率相应增加<sup>[1]</sup>;2)由于种族、文化、经济水平等因素的不同,不同地区的人群间存在差异,因此在胎儿体重估测上也存在较大误差<sup>[2]</sup>,那么就需要针对不同地区甚至不同医院建立个性化的胎儿体重预测方法。

传统的胎儿体重预测模型大多基于单个或多个生理参数

来构建体重预测公式,这些参数包括孕妇的产科检查结果与胎儿超声检查结果。例如:Merz 等<sup>[3]</sup>使用 AC(孕妇腹围)与 BPD(胎儿双顶径)两个参数估测胎儿体重;Schild 等<sup>[4]</sup>使用 BPD, AC, FL(胎儿股骨长)等参数为不同性别的胎儿分别设计了估算公式。但是在众多的公式中,没有一个能够全面且准确地估测胎儿的体重。1992 年, Farmer 等<sup>[5]</sup>提出使用人工神经网络进行胎儿体重的估计。随后 Cheng 等<sup>[6]</sup>将多种方法与人工神经网络融合起来进行胎儿体重的预测。Mohammadi 等<sup>[8]</sup>利用人工神经网络进行双胞胎的体重预测。相对于公式方法,基于人工神经网络的预测模型展现出了诸多优势,但是依旧无法避免使用医学知识进行生理参数选择,这就限制了模型的推广。

近年来,基于深度神经网络来学习高层次特征表示的

李 昆(1992—),男,硕士生,主要研究方向为机器学习、自然语言处理等, E-mail: likun@stu.zzu.edu.cn;柴玉梅(1964—),教授,主要研究方向为机器学习、数据挖掘和自然语言处理, E-mail: ieymchai@zzu.edu.cn。

深度学习<sup>[9]</sup>在众多应用领域都表现出了优异的性能,比如语音识别<sup>[10]</sup>、语音合成<sup>[11]</sup>、图像处理<sup>[12]</sup>、人脸识别<sup>[13]</sup>与自动诊断<sup>[15]</sup>。深度学习通过从经验中获取信息来避免使用人工启发知识,多层的深度神经网络能够使计算机学习到隐含在经验中的复杂概念,建立低级特征与高级语义之间的映射关系<sup>[16]</sup>。本文将深度神经网络引入胎儿体重预测模型的构建中,并提出了一种缺失值补全方法来解决数据中出现的部分数据缺失问题。从郑州大学第三附属医院 2015 年全年所有产科病历中抽取并筛选出共计 6979 例临床数据,将其 80% 作为训练集进行模型的训练,其余 20% 为测试集以供验证模型的性能。实验表明,基于深度神经网络的胎儿体重预测模型相比传统的公式预测方法降低了 8.9% 的预测误差。与此同时,实验结果还证明本文提出的缺失值补全方法有效地强化了对模型的训练,降低了体重预测的误差,提高了预测准确度。

本文第 2 节介绍了使用深度神经网络搭建胎儿体重预测模型的整体思路;第 3 节首先介绍了制定参数提取规则的方法,随后讨论了传统数据缺失值补全方法存在的缺陷及本文补全策略所解决的问题;第 4 节介绍了深度神经网络预测模型的结构与训练过程;第 5 节通过实验对比了本文方法与传统方法,并给出了详细的分析;最后总结了本文的工作,并对进一步的研究进行了讨论。

## 2 基于深度神经网络的预测模型

胎儿体重预测是指在孕妇在分娩之前,通过各种医学检测手段获取孕妇与胎儿的相关信息,进而对胎儿体重进行估算的过程。胎儿体重不仅关系到医务人员对孕妇分娩方式的判断,也可以使孕妇及其家人更加直观地了解胎儿的发育情况。传统的体重预测模型大多基于由医学知识启发得到的一个或多个生理参数,因此参数的选择就是此类方法面临的一个重要问题。为了更加准确地估计胎儿体重,并解决现有方法中存在的问题,本文提出一种基于深度神经网络的胎儿体重预测模型。所有与孕妇、胎儿相关的生理参数无需进行人工选择,深度神经网络会根据大量样本自动学习各个参数与胎儿体重之间的关系,最终形成预测模型。

使用深度神经网络预测胎儿体重的过程如图 1 所示。首先从多年累积的大量电子病历中提取出相关参数,随后针对抽取结果中的部分缺失进行补全,进而完成深度神经网络的训练。训练后的预测模型可用于对未来样本的预测,从而得到胎儿估重。待预测样本可以被直接准备成数值输入预测模型(见图 1),也可以由传统方式记录进病历中,随后通过参数抽取模块提取出符合预测模型所需格式的数据,最后再输入模型。

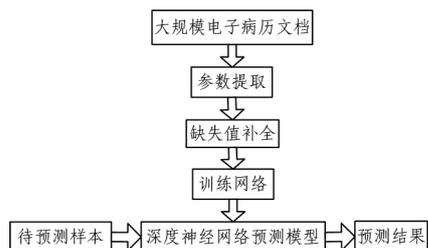


图 1 基于深度神经网络的预测模型示意图

## 3 数据预处理

人工提取、分析与整理大量实验样本是一项非常耗时、耗

力的任务,因此以往的胎儿体重预测模型的构建往往基于数十至数百份临床数据。随着电子病历的逐渐普及与自然语言处理技术的发展,高效、准确地从电子病历中自动抽取所需信息成为了可能,这也使得快速提取大规模临床样本变为了现实。本节将介绍从大量电子病历中提取实验样本的过程,首先介绍从电子病历中提取生理参数的方法,随后深入分析数据缺失问题以及多种有效的缺失值补全策略。

### 3.1 提取生理参数

孕妇与胎儿的各项检查结果记录在电子病例的不同位置,因此需要对整篇病历进行分析与处理才能提取出所需的生理参数作为样本的特征。随后这些提取出的参数还需要通过一定的限制条件进行筛选与校对,才能最终成为样本集合。

不同于一般的文本、生物、医药数据,电子病历中含有大量的个人隐私信息,因此所有与电子病历相关的研究都必须建立在不泄露病例中隐私信息的基础上。大量研究致力于建立电子病历匿名化的标准、方法与工具<sup>[17]</sup>,而本文为了避免病历隐私泄露问题,采用在医院内提取所需参数的方法。随后的模型设计与实验阶段所使用的数据,均不含有任何个人隐私信息。

现阶段的电子病历管理系统多数使用半结构化的方式存储病历,本文所处理的病历也是如此,因此为每个生理参数设计一条或多条正则表达式即可完成参数的提取。制定规则的第一步是观察所需参数的上下文格式,通过对格式的观察就能知晓这些参数的书写规律,并制定出初步的提取规则。有了初步的提取规则,再经过若干次的提取、勘误、补全,即可完成参数提取规则的制定。

病历中参数的上文格式大多数是这项参数的名称,有时会辅以若干形式的标点符号。表 1 展示了部分抽取规则,很明显地可以看出,在这些正则表达式中间数值部分之前都是参数的名称(年龄、宫高、EFW、胎儿估重),一些情况中会出现冒号等标点。而参数的下文大部分由数值的单位组成,并且所有病历中同一个参数的单位是统一的,因此这个单位要唯一限定地写入正则表达式。例如表 1 中宫高使用厘米(cm)作为计量单位,那么对于极少数使用米(m)作为单位的病历就要单独对其进行换算。最后,参数的取值格式也需要进行限定,以避免明显的错误。比如年龄与胎儿估重都取正整数,而宫高的取值在正实数范围内。

表 1 部分参数提取规则

参数名称	抽取规则
年龄	年龄.*?([0-9]{1,})岁
宫高	宫高([0-9]{1,})[.]([0-9]{*})cm
胎儿估重	EFW:([0-9]{1,})[g.] 胎儿估重([0-9]{1,})

虽然深度神经网络能够容忍训练数据中的噪声,但是尽力消除样本中的错误对训练是有利的。对于抽取结果组成的样本集合,可以使用一定的限制条件,筛选出明显不符合常理的数值。这些不合理的数值中,能够被修正的数值可以采取校对后修正的方式处理,而对于无法修正或者修正困难的数值,需要删除对应的样本。

### 3.2 补全缺失值

临床样本中的参数不可避免地会存在缺失值。这些缺失值产生的原因主要有两个,首先就是抽取规则的不完善或是

电子病例中偶尔的格式不统一,其次是因为某项生理参数未进行检查或者未被记录在电子病历中。例如羊水指数(AFI)和脐动脉血流收缩/舒张期速度比(S/D)有时就会出现缺失。常规做法是删除含有缺失值的样本再进行训练,但是存在缺失值的样本也是有价值的,因此可以使用一定的方法补全这些缺失的值,使样本完整。缺失值补全有两方面的意义:1)可以充分利用含有缺失值的样本,强化对模型的训练;2)对缺失值的补全也是保证模型正常训练的必要条件,含有缺失值的样本是不能被用来训练的。

一种很简单的缺失值补全方法是使用平均值补全。假设  $x$  为含有缺失数据的样本集合,  $x'$  是  $x$  的一个子集,表示不含缺失数据的样本集合,其样本数为  $n$ ,  $x \subseteq \mathbb{R}^m$ ,  $x' \subseteq \mathbb{R}^m$ ,  $x_{ij}$  表示第  $i$  个样本的第  $j$  个特征。倘若  $x_{ij}$  缺失,则第  $j$  个特征的平均值赋给  $x_{ij}$ ,即:

$$x_{ij} = \frac{\sum_{k=1}^n x'_{kj}}{n} \quad (1)$$

使用平均值补全的方法基于这样一个假设,即所有未知的值都被认为是“正常的”。也就是说在正态分布下,均值的出现概率比较大,可能的偏差比较小。但是在孕妇、胎儿各项检查结果的补全中,这种方法却违背了“相似的孕妇与胎儿的检查结果也应该是相似的”这一常理。因此本文提出一种基于欧氏距离的补全方法,假设  $x_i \in x, x'_k \in x', j \in \{1, \dots, m\}$ ,  $d_{ik}$  表示  $x_i$  与  $x'_k$  的欧氏距离:

$$d_{ik} = \sqrt{\sum_{j=1}^m (x_{ij} - x'_{kj})^2} \quad (2)$$

$$k^* = \operatorname{argmin}_k d_{ik} \quad (3)$$

$$x_{ij} = x'_{k^*j} \quad (4)$$

基于欧氏距离的补全方法满足了相似孕妇与胎儿应有相似检查结果这一常理,但由于各个指标之间度量单位与取值范围的不同,使用式(2)~式(4)所示方法计算出的欧式距离有时会导致严重的错误。例如,样例 a 的年龄为 25,停经时间为 9 个月,样例 b 的年龄为 26,停经时间为 6 个月,虽然两个样例年龄之差小于停经月数之差,但是停经月数显然要比年龄对胎儿体重的影响更大。针对这种错误,本文使用加权欧氏距离的补全方法来强化或削弱不同特征的重要性,其权值  $w$  使用多元线性回归学习。权值越大,即对胎儿体重影响因素越大的特征对距离的影响越显著。令  $w_j$  表示第  $j$  个特征的权值,  $d_{ik}$  依旧为  $x_i$  与  $x'_k$  的欧氏距离:

$$d_{ik} = \sqrt{\sum_{j=1}^m [w_j (x_{ij} - x'_{kj})]^2} \quad (5)$$

$$k^* = \operatorname{argmin}_k d_{ik} \quad (6)$$

$$x_{ij} = x'_{k^*j} \quad (7)$$

在学习  $w$  时,使用多元线性回归拟合不含缺失值的集合  $x'$ 。随后将所有非正权值置为 0,正权值由  $(0, +\infty)$  映射到  $(0, 1]$ 。

#### 4 深度神经网络的结构与训练

无论是使用早期基于公式的预测模型,还是使用传统人工神经网络构建的体重预测模型,都不可避免地要进行输入参数的筛选,即特征选择。其目的在于只保留与胎儿体重有明显关联的生理参数,并且剔除无关参数以防影响预测。在此状况下,许多基于不同参数的方法被提出,有些方法之间使

用的参数甚至没有交集。由此可见,各项生理参数与胎儿体重之间的关系并没有定论。针对这种情况,本文提出使用深度神经网络构建胎儿体重预测模型,深度学习方法无需利用医学经验知识筛选输入参数,只需使用大量的样本进行训练,即可根据所有的孕妇及胎儿超声检查参数预测胎儿的体重。

由于不同特征(即生理参数)往往具有不同的量纲与量纲单位,因此在输入进网络之前要进行标准化处理,以确保各个特征处在同一数量级。特征标准化方法如式(8)所示,其中  $\mu$  为当前特征的均值,  $\sigma$  为当前特征的标准差。

$$x^* = \frac{x - \mu}{\sigma} \quad (8)$$

经过标准化的特征符合标准正态分布,均值为 0,标准差为 1,损失函数所需的真实体重无需进行标准化。随后这些作为样本特征的生理参数通过输入层进入神经网络。本文提出的神经网络结构如图 2 所示,输入层由多个分支组成,不同的分支接收不同类型的参数,每个分支内可以存在一个或多个分支隐含层。这些分支通过一定方式合并以后会再通过若干隐含层,并最终到达输出层,输出层只有一个节点产生预测结果。使用多个分支作为网络输入层的原因在于生理参数可以被显著地分为若干个类,各个类之间的参数又往往不相关。比如孕妇产检与胎儿超声检查是两个分开进行的检查项目,其检查时间、检查方式均不相同。

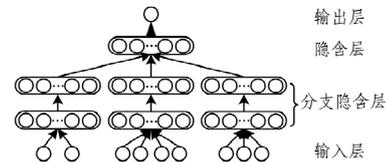


图 2 预测模型中的深度神经网络结构

本文针对胎儿体重预测使用的深度神经网络结构有 3 个输入分支,分别接收 3 种来源不同的生理参数。这 3 类参数分别为产科检查结果、胎儿超声检查结果与常规检查结果,每个分支的输入维度由每个类别的生理参数数目决定,本文使用的 3 类参数见表 2。

表 2 使用的参数及所属类别

类别	参数
产科检查结果	IS, IC, EC, TO, 宫高, 腹围
胎儿超声检查结果	BPD, FL, AFI, S/D, 头位
常规检查结果	年龄, 停经月数, 孕期体重增加量, 体温, 脉搏, 心率, 收缩压, 舒张压

参数由输入层进入网络的不同分支以后,将通过若干分支隐含层,随后使用连接方式合并。例如,倘若最终分支隐含层的输出维度均为 200,那么合并以后的维度大小为 600,而与之相对应的加法方式合并以后的维度大小为 200。隐含层与隐含层之间使用 Dropout<sup>[20]</sup> (Fraction=0.5) 防止过拟合,除了与输出层连接的隐含层使用线性激活函数,其他均使用 Relu 激活函数。在常用的神经网络训练方法的基础上,基于深度神经网络的胎儿体重预测模型的训练过程如算法 1 所示。

#### 算法 1 胎儿体重预测模型的训练

输入: 产科病历文本

输出: 训练后的深度神经网络

- 1) 病历文本中提取的参数;
- 2) If  $\alpha$  中存在缺失值 then

```

    补全 x 中的缺失值;
End if
3) 标准化处理 x;
4) While 未达到最大迭代周期 do
    将 x 输入网络, 前向传播并计算误差 J;
    反向传播并更新权重 w;
    If 验证集误差 J' 连续 20 个周期高于 min J then
        Break;
    End if
End while

```

## 5 实验与结果分析

大量的训练样本是保证神经网络性能的重要前提条件,同时为了保留数据原始的分布特征,本文从郑州大学第三附属医院 2015 年 1 月 1 日至 2015 年 12 月 31 日所有产科病历中抽取了 6979 例符合实验要求的样本。这些样本满足的条件为:单胎,孕期 6~10 个月,年龄 19~46 岁,在分娩前 5 天内接受过产科检查或者胎儿超声检查。样本集的 80% 作为训练集训练模型,剩余 20% 为测试集以供评价模型性能。在训练过程中,每个周期都随机使用 75% 的训练样本调整网络权重,并将其余的 25% 作为验证集以提前停止迭代,防止过拟合的同时也可以节约计算资源。

两个指标被用来衡量预测模型的性能。第一个指标是均方根误差(Root Mean Square Error, RMSE),这个指标作为回归分析中常用的评价标准,能够很好地表现出预测的准确度。并且,均方根误差的量纲与原始数据一致,因此能够更直观地对误差进行比较。第二个是依照妇产科学传统标准,将预测体重与真实体重相差 250 克以内的作为准确的预测,进而计算预测准确率。换言之,所有预测值与真实值之差的绝对值在 250 以内的将会被判定为预测正确,反之则被判定为预测错误。实验结果如表 3 所列,Formula 表示电子病历中的公式计算方法,MLR、ANN、DNN 分别表示多元线性回归模型、传统神经网络模型、深度神经网络模型,Mean、Nearest 与 Weighted\_nearest 分别表示均值补全方法、最近邻补全方法以及加权最近邻补全方法。

表 3 胎儿体重预测方法对比

方法	均方根误差(g)	准确率(%)
Formula	376.51	57.48
MLR+Mean	430±50	40.31±1.9
MLR+Nearest	470±30	38.30±1.1
MLR+Weighted_nearest	41750	40.26±2.0
ANN+Mean	357±10	53.25±0.4
ANN+Nearest	362±8	53.41±0.3
ANN+Weighted_nearest	355±10	54.11±0.3
DNN+Mean	35±52	54.39±0.1
DNN+Nearest	36±17	53.54±0.3
DNN+Weighted_nearest	34±34	57.94±0.2

实验结果表明,简单的多元线性回归相对于公式计算方法还有一定的差距。而传统的人工神经网络模型的均方根误差低于公式计算方法,特别是深度神经网络的应用又进一步地降低了预测误差。在缺失值补全策略中,无论是基于 MLR、ANN 或者是 DNN,使用最近邻补全方法的预测误差普遍高于平均值补全方法,但是经过对权值的调整,加权最近邻补全方法的预测误差低于平均值补全方法。

在加权最近邻补全方法中使用的权重通过多元线性回归

进行学习,随后进行一定的变换处理。所有非负权重被映射到(0,1]的范围内,而负权重全部设置为 0。映射后小于 0.01 的值设置为 0.01。表 4 展示了本文实验中使用多元线性回归拟合不含缺失值集合  $\alpha^1$  所得到的权重和经过处理后相对应的值。

表 4 加权最近邻方法使用的权重

参数	原始权重	处理后的权重
年龄	1.36	0.01
停经月数	393.94	1
孕期体重增加量	3.21	0.01
体温	-120.21	0
脉搏	1.1	0.01
心率	37.78	0.09
收缩压	-7.82	0
舒张压	4.97	0.01
IS	-9.54	0
IC	4.06	0.01
EC	-33.65	0
TO	99.50	0.75
宫高	24.97	0.06
腹围	12.11	0.03
BPD	8.21	0.02
FL	16.25	0.04
AFI	1.72	0.01
S/D	-245.16	0
头位	23.67	0.06

本文对比了公式方法与深度神经网络模型预测误差在各个范围内所占的比例,如图 3 所示。相对于公式预测方法,深度神经网络模型的预测误差更多地处在 100g 至 500g 之间。而公式方法在一些情况下预测得很准确(误差小于 100g),但是有时也会出现较大的误差(大于 500g)。这说明本文提出的深度神经网络模型可以减少严重的预测失误。

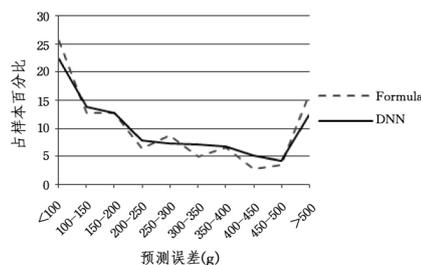


图 3 预测误差在各范围的对比

结束语 本文针对胎儿体重预测模型现阶段存在的问题:1)提出使用深度神经网络结构建立体重预测模型;2)介绍了基于电子病历的参数提取方法;3)提出了有效的缺失值补全策略。本文提出的方法有很强的通用性,能够针对不同地区、不同医院个性化地构建出不同的胎儿体重预测模型。实验结果表明,本文提出的深度神经网络模型优于公式预测方法与基于人工神经网络的方法。此外,本文提出的缺失值补全策略也可以有效地利用含有缺失值的样本,强化对模型的训练并提高预测的准确性。对实验结果的深入分析表明,虽然深度神经网络模型在误差大于 500 克的情况下优于传统方法,但是比例仍然较高。因此进一步的研究可以关注于使用深度神经网络降低严重预测失误的概率。

## 参考文献

- [1] 刘致君,李桂荣,郭兴巧.预测胎儿体重新方法与传统方法的比较[J].中国妇幼保健,2008,23(24):3478-3479

(下转第 82 页)

社会稳定及教育等多个方面的发展具有非常重要的意义。本文所设计的维吾尔多文统一转换引擎实现了多种维语文字向统一的老维文的准确转换。这使国内外维族网民可以便捷地在不改变自身维文使用习惯的基础上使用现有的维文搜索引擎。由此,本文的研究成果对现有的维文搜索引擎及国内外维族网民的日常互联网使用具有重要的实际意义。未来工作方向包括:进一步提高原型系统的稳定性及处理效率,完成接口通用化;设计一套完整的维吾尔多文统一元搜索引擎系统,结合现有的维文、通用互联网搜索引擎为广大维族网民服务。

## 参 考 文 献

[1] Turditohti, akbar, askarhamdulla. Adaptive word grouping algorithm based on mutual information in Uyghur language[J]. 计算机应用研究, 2013, 30(2): 82-85

[2] 图尔妮萨麦提, 吾守尔斯拉木. 现代维吾尔文与斯拉夫维吾尔文转换规则研究[J]. 标准化研究, 2013, 9: 56-59

[3] 吐尔地托合提, 维尼拉木沙江, 艾斯卡尔艾木都拉. 基于词间关联度度量的维吾尔文自动切分方法[J]. 北京大学学报, 2016, 52(1): 155-162

[4] 亚森依明. 基于国际标准编码系统的维文拉丁文转写规则研究[J]. 标准化研究, 2011, 6: 49-51

[5] 赵永霄, 哈力旦阿布不都热依木. 面向增量同生主题的维吾尔文爬虫的研究[J]. 计算机应用, 2014, 31(11): 3269-3272

[6] 李连倍. 基于跨语本体重用的维文本体构造方法研究[D]. 乌鲁木齐: 新疆大学, 2014

[7] 沙吾提江亚森. 基于本体的维文语义搜索引擎的研究与实现[D]. 成都: 电子科技大学, 2015

[8] 瓦依提阿布力孜, 依不拉音吾斯曼, 阿依佐克拉. 提高维吾尔搜索引擎质量的一些关键技术[J]. 数学的实践与认识, 2013, 43(3): 119-122

[9] 艾孜尔古丽, 齐向卫, 玉素甫. 基于网站用词调查的现代维吾尔语词干提出和应用研究[J]. 计算机应用与软件, 2012, 29(3): 32-34

[10] 刘丽杰. 基于量子行为进化算法的聚集爬虫搜索策略[J]. 计算机应用研究, 2012, 29(11): 4281-4283

[11] 王新青, 池中华. 丝绸之路经济带中亚 5 国语言状况考察与思考[J]. 云南师范大学学报(社会科学版), 2015, 47(5): 14-20

[12] 陈国华, 汤庸. 基于学术社区的学术搜索引擎设计[J]. 计算机科学, 2011, 38(8): 171-175

[13] 岑荣伟. 基于用户行为分析的搜索引擎评价研究[D]. 北京: 清华大学, 2010

[14] 徐戈, 王厚峰. 自然语言处理中主题模型的发展[J]. 计算机学报, 2011, 34(8): 1424-1433

[15] 江腾蛟, 万常选, 刘德喜. 基于语义分析的评价对象-情感词对抽取[J]. 计算机学报, 2016, 39: 1-15

[16] 付剑生, 徐林龙. 分布式全网职位搜索引擎的研究与实现[J]. 计算机技术与发展, 2015, 25(5): 6-9

[17] <http://www.xjuloud.com>

[18] <http://www.izda.com>

[19] <http://www.ulinux.com>

(上接第 76 页)

[2] 唐慧霞, 李胜利. 超声估测胎儿体重的研究进展[J]. 中华医学超声杂志(电子版), 2014, 11(5): 9-14

[3] Merz E, Lieser H, Schicketanz K H, et al. Intrauterine fetal weight assessment using ultrasound. A comparison of several weight assessment methods and development of a new formula for the determination of fetal weight[J]. Ultraschall in der Medizin (Stuttgart, Germany; 1980), 1988, 9(1): 15-24

[4] Schild R L, Sachs C, Fimmers R, et al. Sex-specific fetal weight prediction by ultrasound[J]. Ultrasound in Obstetrics & Gynecology, 2004, 23(1): 30-35

[5] Farmer R M, Medearis A L, Hirata G I, et al. The use of a neural network for the ultrasonographic estimation of fetal weight in the macrosomic fetus[J]. American Journal of Obstetrics and Gynecology, 1992, 166(5): 1467-1472

[6] Cheng Y C, Hsia C C, Chang F M, et al. Cluster-Based Artificial Neural Network on Ultrasonographic Parameters for Fetal Weight Estimation[C]// 6th World Congress of Biomechanics (WCB 2010). 2010 Singapore. Springer Berlin Heidelberg, 2010: 1514-1517

[7] Cheng Y C, Chiu Y H, Wang H C, et al. Using Akaike information criterion and minimum mean square error mode in compensating for ultrasonographic errors for estimation of fetal weight by new operators[J]. Taiwanese Journal of Obstetrics and Gynecology, 2013, 52(1): 46-52

[8] Mohammadi H, Nemati M, Allahmoradi Z, et al. Ultrasound estimation of fetal weight in twins by artificial neural network[J]. Journal of Biomedical Science and Engineering, 2011, 4(1): 46

[9] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507

[10] Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, 29(6): 82-97

[11] 王坚, 张媛媛. 基于深度神经网络的汉语语音合成的研究[J]. 计算机科学, 2015, 42(6A): 75-78

[12] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]// Advances in Neural Information Processing Systems. 2012, 25(2): 1097-1105

[13] 王莹, 樊鑫, 李豪杰, 等. 基于深度网络的多形态人脸识别[J]. 计算机科学, 2015, 42(9): 61-65

[14] 李海朋, 李晶皎, 闫爱云, 等. 人脸识别中的遗传神经网络并行实现[J]. 计算机科学, 2015, 42(6A): 168-174

[15] Lipton Z C, Kale D C, Elkan C, et al. Learning to Diagnose with LSTM Recurrent Neural Networks[J]. Computer Science, 2015

[16] 孙志远, 鲁成祥, 史忠植, 马刚. 深度学习研究与进展[J]. 计算机科学, 2016, 43(2): 1-8

[17] Uzuner Ö, Luo Y, Szolovits P. Evaluating the state-of-the-art in automatic de-identification[J]. Journal of the American Medical Informatics Association, 2007, 14(5): 550-563

[18] Stubbs A, Uzuner Ö. Annotating longitudinal clinical narratives for de-identification: The 2014 i2b2/UTHealthcorpus[J]. Journal of Biomedical Informatics, 2015, 58: S20-S29

[19] Stubbs A, Kotfila C, Uzuner Ö. Automated systems for the de-identification of longitudinal clinical narratives: Overview of 2014 i2b2/UTHealth shared task Track 1[J]. Journal of Biomedical Informatics, 2015, 58: S11-S19

[20] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958