

基于 BP 神经网络的智能轮胎标签仿真研究

宋廷强, 齐艳丽

(青岛科技大学 信息科学技术学院, 山东 青岛 266042)

摘要: 为了更加快捷方便地研究 RFID 标签植入环境与阅读器阅读距离之间的关系, 从而预测植入轮胎中的 RFID 标签的最大阅读距离; 利用 FEKO 电磁仿真软件建立了不同情况下的天线, 并仿真得到反射系数 S_{11} , 然后用弗林斯传输方程 (Friis) 计算得到仿真读取距离, 再利用 MATLAB 强大的数据处理能力, 建立 BP 神经网络预测模型, 从而建立起标签天线长度、轮胎中标签与钢丝层的距离、轮胎介电常数和已得到的仿真读取距离之间的 BP 神经网络模型; 最后实际测量值与训练后得到的预测仿真值在误差允许的范围可以认定为实际测量距离; 此方法可以通过建立 BP 神经网络模型, 快速方便地在一定精度范围内预测阅读器的阅读距离。

关键词: RFID; 标签; 轮胎; BP 神经网络

Simulation to Intelligent Tire Tag Based on BP Neural Network

Song Tingqiang, Qi Yanli

(Department of Computer Systems Structure, Qingdao University of Science and Technology, Qingdao 266042, China)

Abstract: In order to study the relationship between RFID tag implantation environment and Readers read distance, thereby predicting the maximum reading distance of the RFID tag implanted into the tire; the FEKO electromagnetic simulation software established many antennas with different conditions and the reflection coefficient S_{11} is obtained, And then use the Frings transfer equation (Friis) to calculate the simulation read distance. In MATLAB, there are neural network toolboxes that can be called, and the BP neural network prediction model is established by using MATLABs powerful data processing ability to establish the length of the tag antenna, the distance between the label and the wire layer in the tire, the tire dielectric constant and the simulation of the distance between the BP neural network model. ; At last, The actual measured value and the predicted simulation value obtained after training can be regarded as the actual measurement distance within the allowable range of error; Therefore, the BP neural network model can be used to predict the reading distance of the reader within a certain precision range quickly and easily.

Keywords: RFID; tag antenna; tires; BP neural network

0 引言

轮胎 RFID 标签是轮胎数字化的重要形式, 植入 RFID 标签的轮胎可以方便的实现产品的跟踪、定位、追溯等多个环节, 给商品生产及管理带来巨大的便利性^[1-2]。然而, 橡胶中的炭黑等成分对 RFID 标签信号的传输产生了很大的影响, 有文献指出 915 MHz 的 RFID 芯片在空气下可以达到 106 cm 传输距离, 而植入轮胎侧壁后, 读取距离降至 10 cm 以下^[3-5]。

因此, 需要使用合适的方法来建立标签传输距离和对标签的影响参数之间的关系。BP 神经网络 (Back Propagation) 是人工神经网络的一种, 是一种模仿动物神经网络行为特征, 进行分布式并行信息处理的算法数学模型。这种网络有两个优点。首先, 不需要假设函数 $f(x)$ 的数学结构, 也就是不需要对 $f(x)$ 和 x 之间具体的对应关系进行研究。其次, 反向前馈网络在模型建立过程中会根据误差不断调整权值, 因此建立的 $f(x)$ 模型精度很高。

本文将仿真的得到的影响标签传输距离的参数作为 BP 神经网络的模型输入数据, 将与标签读取距离相关性比较大的反射系数作为模型输出数据。从而利用 BP 神经网络的优良性能

预测标签读取的最优距离。

1 BP 神经网络介绍

BP (Back Propagation) 神经网络是 1986 年由 Rumelhart 和 McClelland 为首的科学家小组提出, 是一种按误差逆传播算法训练的多层前馈网络, 是目前应用最广泛的神经网络之一。

BP 神经网络的模型如图 1 所示, 输入 x , 输出 y , 权值为 ω , 阈值函数为 f 。其基本模型与人工神经网络模型大体一致。




图 1 BP 神经网络的一般模型

BP 神经元和其他的神经元比较相像, 相异的是 BP 神经元的传输函数是非线性的, 最常用的函数是 logsig 和 tansig , 有的输出层也采用线性函数。输出为:

$$a = \text{logsig}(W_p + b) \quad (1)$$

BP 神经网络一般为多层神经网络。由 BP 神经元可以构成的多层网络。BP 神经网络的信息从输入层流向输出层, 因此是一种多层前馈网络^[6]。

BP 神经网络模型 BP 网络模型包括输入输出模型, 作用

收稿日期: 2017-02-14; 修回日期: 2017-03-02。

基金项目: 山东省自然科学基金 (ZR2013FL011); 绿色轮胎与橡胶协同创新中心开放课题 (2014GTR0020)。

作者简介: 宋廷强 (1973 -), 男, 山东青岛市人, 副教授, 硕士生导师, 主要从事研究嵌入式方向研究。

函数模型, 误差继续按摩型和自学习模型。

1) 节点输出模型。隐节点输出模型为:

$$O_j = f(\sum W_{ij} \times X_i - q_j)$$

输出节点输出模型为:

$$Y_k = f(\sum T_{jk} \times O_j - q_k) \quad (3)$$

其中: f 为非线性作用函数; q 为神经元阈值。

2) 作用函数模型。作用函数是反映下层输入对上层节点刺激脉冲强度的函数, 又称刺激函数, 一般取为 (0, 1) 内连续取值的 sigmoid 函数:

$$f(x) = \frac{1}{1+e^{-x}} \quad (4)$$

3) 误差计算模型。误差计算模型是反映神经网络期望输出与计算书处之间误差的大小的函数:

$$E_q = \frac{1}{2} \times \sum (t_{pi} - O_{pi})^2 \quad (5)$$

其中: t_{pi} 为节点的期望和输出值; O_{pi} 为节点计算输出值。

4) 自学习模型。神经网络的学习过程, 即连接下层节点和上层节点之间的权重矩阵 W_{ij} 的设定和误差修正过程。BP 网络有师学习方式—需要设定期望值和无师学习方式—只需输入模式之分。自学习模型为

$$\Delta W_{ij}(n+1) = h \times \Phi_i \times O_j + a \times \Delta W_{ij}(n) \quad (6)$$

其中: h 学习因子; Φ_i 输出节点 i 的计算误差; O_j 输出节点 j 的计算输出; a 为动量因子^[7]。

2 神经网络模型

2.1 神经网络预测优点

神经网络预测有两个优点:

1) 不需要假设函数 $f(x)$ 的数学结构, 也就是不需要对 $f(x)$ 和 x 之间具体的函数关系进行研究, 只需要弄清楚两者之间的映射关系即可。因此, 本文中可以直接利用输入输出数据来建立对应模型。

2) 反向前馈网络在模型建立过程中会根据误差不断调整权值, 因此建立的 $f(x)$ 模型精度很高。

2.2 Matlab 神经网络工具箱

在 Matlab 中建立神经网络时, 主要调用工具箱中的函数, 因此在 Matlab 神经网络工具箱中提供了若干函数用于实现 BP 网络的学习。

2.3 建模步骤

BP 算法是利用输出层的误差来估计输出层的直接前导层的误差, 再用这个误差估计更前一层的误差。如此下去, 就获得了所有其他各层的误差估计。这样就形成了将输出端表现出的误差沿着与输入信号传送相反的方向逐级向网络的输入端传递的过程。BP 神经网络建模的过程, 也就是批处理 BP 神经网络算法的编程步骤流程图见图 2, 具体步骤如下所示:

1) 初始化: 对权值矩阵 W 、 V 赋随机数, 将样本模式计数器 and 训练次数计数器 q 置为 1, 误差 E 置为 0, 学习率 η 设为 (0, 1] 区间内的小数, 网络训练后达到的精度 E_{min} 设为一正的小数。

2) 输入第一对训练样本, 计算各层输出: 用当前样本 X^p 、 d^p 对向量数组 X 、 d 赋值, 用公式 (7) 和公式 (8) 计算隐含层输出 Y 和输出层输出 0 中各分量。当前样本值为神经网络的输入, 即影响读取距离的参数, $X^p = (35, 9, 0,$

表 1 BP 神经网络工具箱

函数类型	函数名称	函数用途
创建函数	Newcfc	创建级联前向 BP 网络函数
	Newff	创建前向神经网络
传递函数	Logsig	传递函数为 S 型的对数函数
	Tansig	传递函数为双曲正切函数
学习函数	learngd	实现 BP 梯度下降学习
	learnqdm	梯度下降动量函数
训练函数	trainfg	BFGS 准牛顿 BP 算法函数
	traingd	梯度下降 BP 算法函数
	traingdm	梯度下降动量 BP 算法函数
	traindx	快速 BP 算法
性能函数	mse	实现 BP 网络的均方误差性能函数
显示函数	plotperf	绘制一个单独神经元误差曲面
	errsurf	计算单个神经元的误差曲面

3, -15, 2, 30, 0. 8), 这些参数作用下, 若使得特定功率的阅读器阅读距离为 1 m, 则 $d^p = 1$ 。

$$O_k = f\left(\sum_{j=0}^m \omega_{jk} y_j\right) \quad k = 1, 2, \dots, l \quad (7)$$

$$Y_j = f\left(\sum_{i=0}^n v_{ij} x_i\right) \quad j = 1, 2, \dots, m \quad (8)$$

其中: O_k 是实际输出, Y_j 是隐含层输出, $f(\cdot)$ 是选定的转移函数, v 是隐含层权值, ω 是输出层权值。因为人工神经网络是三层结构, i 代表输入层的数目, j 代表隐含层的数目, k 代表输出层的数目。

3) 计算网络误差: 在所有的影响性能参数和读取距离的样本输入之后, 计算网络的总误差为:

$$E_{\text{总}} = \sqrt{\frac{1}{2} \sum_{p=1}^P \sum_{k=1}^l (d_k^p - o_k^p)^2} \quad (9)$$

其中: $E_{\text{总}}$ 为所有样本输入之后的总误差, 用于之后和设定的期望误差 E_{min} 比较。 d 为所有的影响读取距离参数取值后, 特定功率的阅读器所读取的实际阅读距离, 即测量距离。 0 为神经网络的实际输出值。 P 是样本值数编号。

4) 检查是否对所有的样本完成一次轮训若 $p < P$, 计数器 p 增 1, 返回步骤 2), 否则, 转步骤 5)。

5) 计算各层误差信号: 应用公式 (10) 和公式 (11) 计算神经网络的输出值和我们所测量的真实值间的误差。输出层误差 δ_k^o 和隐含层误差 δ_j^y 。如下:

$$\delta_k^o = -\frac{\partial E}{\partial net_k} = (d_k - o_k) o_k (1 - o_k) \quad (10)$$

$$\delta_j^y = -\frac{\partial E}{\partial net_j} = \left(\sum_{k=1}^l \delta_k^o \omega_{jk}\right) y_j (1 - y_j) \quad (11)$$

6) 调节各层权值: 我们根据上面计算的误差来调节内部权 ω 和 v , 以减小神经网络的输出值与我们测量到的真实读取距离之间的差距。应用公式 (12) 和公式 (13) 计算 ω , v 中的分量。

$$\Delta \omega_{jk} = -\eta \frac{\partial E}{\partial \omega_{jk}} = \eta \delta_k^o y_j = \eta (d_k - o_k) o_k (1 - o_k) y_j \quad (12)$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} = \eta \delta_j^y x_i \left(\sum_{k=1}^l \delta_k^o \omega_{jk}\right) y_j (1 - y_j) x_i \quad (13)$$

注: 步骤 4) ~ 6) 主要是对权值的一个调整过程, 通过计算出的 $E_{\text{总}}$ 来计算各层误差, 调整权值。上面的 E 即为我们计算出的总误差 $E_{\text{总}}$ 。

7) 计数器 q 增 1。

8) 检查网络总误差是否达到精度要求：例如，当用 $E_{\text{总}}$ 作为网络的总误差时，若满足 $E_{\text{总}} < E_{\text{min}}$ ，即输出的阅读距离的值和我们实际测量到的阅读距离的值已经存在很小的误差。训练结束，否则 E 置零， p 置 1，返回步骤 2)。




图 4 植入橡胶块的 RFID 标签

对不同螺旋天线的介电常数、植入深度和距离钢丝层的距离的仿真，可以得到不同的如反射系数、增益等仿真参数，通过已知和仿真得到的参数计算出标签的读取距离。然后，进行神经网络的模型建立。具体数据见表 2。

表 2 神经网络建模输入数据

组数	天线单臂长/mm	轮胎介电常数/(F/m)	植入轮胎位置	
			钢丝层距离/mm	植入深度/mm
1	1.5	1.5	3.0	6.0
2	3.5	3.5	3.0	6.0
3	6.0	6.0	3.0	6.0
4	1.5	1.5	5.0	6.0
5	3.5	3.5	5.0	6.0
6	6.0	6.0	5.0	6.0
7	1.5	1.5	8.0	6.0
8	3.5	3.5	8.0	6.0
9	6.0	6.0	8.0	6.0
10	3.5	3.5	5.0	3.0

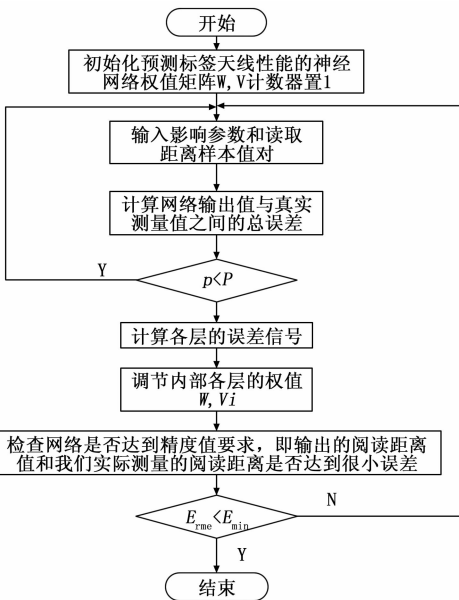


图 2 BP 网络训练流程图

根据以上步骤可以对神经网络进行训练，然后得出拟合曲线。

3 神经网络模型应用

3.1 模型准备

3.1.1 输入参数——天线单臂长、植入深度、钢丝层距离

使用 EMSS FEKO 进行螺旋偶极子天线的建模，如图 3 所示。螺旋角 ($A=12.1^\circ$) 和螺旋半径 ($R=0.565 \text{ mm}$) 已经确定，因此，将对螺旋天线的介电常数、植入深度和距离钢丝层的距离进行电磁仿真，将得到的参数作为神经网络模型的输入数据，并且将根据仿真参数的道德标签阅读距离作为神经网络的模型输出。通过建立的 BP 神经网络来预测不同输入下的阅读距离。

如图 3 所示。螺旋角 ($A=12.1^\circ$) 和螺旋半径 ($R=0.565 \text{ mm}$) 已经确定，因此，将对螺旋天线的单臂长进行不同的取值，进行电磁建模仿真，以此来研究螺旋线臂长和读取距离的关系。图 4 为标签的植入深度和与钢丝层的距离。其中植入深度为标签到轮胎侧壁最外侧的距离，而与钢丝层距离为标签到钢丝层末端的距离。经试验验证，这两个参数对标签的传输距离影响比较大。



图 3 螺旋天线仿真模型

3.1.2 输出参数——阅读器读取距离

识别距离是衡量 RFID 标签传输性能比较重要的参数。RFID 标签的识别距离一般包括标签的激活距离和阅读器能够检测到的距离。一般来说，它们两者之间较小的值即为所求的最大阅读距离。

一般可以通过弗林斯传输方程 (Friis) 来计算读取距离。Friis 传输理论用于解释并确定无线电通信线路中被无损耗且与负载匹配的天线所接收到的功率。如图 5 所示，发射机将发射功率为 P_t 的能量馈送给具有增益为 G_t 的发射天线，在距离 R 处有一接收天线，此接收天线的增益为 G_r ，并设接收机由接收天线而接收到的功率为 P_r 。




图 5 发射和接收天线原理图

在自由空间，无损耗，极化匹配，端口匹配的情况下接收天线所接收到的信号功率为：

$$P_r = \frac{P_t G_t}{4\pi R^2} \quad (14)$$

这就是弗林斯传输公式。这个等式关系自由空间路径损耗，天线增益和天线接收和发射功率。其中， P_t 为标签天线的接收功率，即标签的最低开启功率； P_r 为读写器天线的发射功率； G_t 为读写器天线的发射增益； G_r 为标签天线的接收

增益; R 是标签天线与读写器发射天线之间的距离。

上式 (14) 可知, 频率越高, 接收天线接收到的功率越低, 也就意味着衰减越大。

利用 Friis 自由空间传输公式可知, 在任意给定 P_t 、 G_t 、 P_r 、 G_r 、 R 五个量中的任意四个量之后, 剩余的一个量必定可求。于是可以得到标签的最大读取距离公式:

$$R = \frac{\lambda}{4\pi} \sqrt{\frac{P_t G_t G_r}{P_r}} \quad (15)$$

若用芯片的灵敏度为 P_{th} , 那么 P_{th} , 则 Friis 传输方程可以如下式表示:

$$R_{tag} = \frac{\lambda}{4\pi} \sqrt{\frac{P_t G_t G_r \tau}{P_{th}}} \quad (16)$$

其中: τ 为功率传输系数。

如果用 s 表示反射因子, 反映等效电源能够传输给负载的最大功率的百分之多少没有传输给负载, 而是被反射了, 该因子是与 τ 相对的概念, 二者的关系为:

$$\tau = 1 - |s|^2, 0 \leq \tau \leq 1 \quad (17)$$

当 $\tau=1$ 时, 表示标签芯片与标签天线完全匹配, 此时标签可以达到最大识别距离。而根据反射系数 S_{11} 的定义可得:

$$S_{11} = s \quad (18)$$

所以, 我们在已知 RFID 标签和阅读器的功率和增益的情况下, 可以得到读取距离和反射系数:

$$R_{tag} = \frac{\lambda}{4\pi} \sqrt{\frac{P_t G_t G_r (1 - S_{11}^2)}{P_{th}}} \quad (19)$$

因此, 通过仿真得到的不同橡胶材料和不同天线尺寸情况下的标签反射系数值, 可以得到标签的读取距离。

3.2 BP 神经网络模型建立

使用 Matlab 进行神经网络的训练, 并最终建立稳定的模型。此时, 当输入不同螺旋天线的介电常数、植入深度和距离钢丝层的距离的数值时, 便会通过模型得到相应的模型输出, 也就是读取距离。以下为部分代码:

```
P=[1.5 3.5 6.0 1.5 3.5 6.0 1.5 3.5 6.0 ;
3.0 3.0 3.0 5.0 5.0 5.0 8.0 8.0 8.0 ;
6.0 6.0 6.0 6.0 6.0 6.0 6.0 6.0 6.0];
T=[9.5 8.0 6.0 9.0 7.5 5.0 8.5 7.0 4.5];
% 创建神经网络
net=newff( minmax(P), [8, 6, 1], {'tansig','tansig','purelin'}, 'trainlm');
% 两次训练之间的训练次数
net.trainParam.show=100;
% 设置训练次数
net.trainParam.epochs = 500;
% 设置收敛误差
net.trainParam.goal=0.00001;
% 训练神经网络
[net,tr]=train(net,P,T);
% 预测输入数据
a=[1.5 3.0 6.0;3.5 3.0 6.0;6.0 3.0 6.0;1.5 5.0 6.0;3.5 5.0
3.0];
% 神经网络仿真
b1=sim(net,a);
y=[T b1];
% 误差分析
y1=[T(1:4) 7.8];
```

```
E=b1-y1;
% 图像显示
figure(1);
plot( (1:9),T,'-+r',(1:14),y,'--ob');
xlabel('试验组数) % 标记横坐标
ylabel('标签阅读距离'); % 标记纵坐标 title('不同情况下的标签阅读距离) % 给图形添加标题
figure(2);
plot((1:5),E,'- * b');
xlabel('验证组数)
ylabel('阅读距离误差');
title('阅读距离误差分析)
```

3.3 模型验证

模型建立后, 为了验证得到的模型是否正确, 或者时候在允许的误差范围之内, 需要对神经网络模型进行验证。利用 3.1 中神经网络建模数据表中前 9 组为建模数据, 模型建好后, 将前 4 组数据和最后一组未使用过的数据, 共 5 组数据作为预测数据, 来对神经网络模型的准确性进行验证。

如图 6 所示, 由实线构成的是前 9 组用于模型建立的数据, 后 5 组则是为验证模型准确性的预测数据。由预测数据中的前 4 组取自模型建立的数据, 因此得到的读取距离与前者是基本一致的, 误差也非常的小。第 5 组的预测数据与所测数据误差也非常接近, 误差在 0.045 之内, 见图 7。




图 6 神经网络预测数据图




图 7 神经网络误差分析图

预测数据值和与实际数据值及两者之间的误差详细结果如表 3 所示。从表中可以得出, 预测值与实际值之间的误差大约在之内, 这相比与我们所需要的读取距离单位来说, 误差在忽略范围内, 可以认为建立的模型是准确的。所以通过建立的 BP 神经网络模型, 已知轮胎介电常数、钢丝层距离和植入深

度的情况下，得到植入轮胎的 RFID 标签的读取距离。

表 3 误差分析表

输入值			输出值		误差/dm
介电常数/(F/m)	钢丝层距/mm	植入深度/mm	预测值/dm	实际值/dm	
1.5	3.0	6.0	9.4999	9.5	-8.4239e-05
3.5	3.0	6.0	7.9997	8.0	-0.0003
6.0	3.0	6.0	6.0000	6.0	-1.8763e-05
1.5	5.0	6.0	9.00000	9.0	-9.8313e-06
3.5	5.0	3.0	7.8419	7.8	0.0419

4 结论

BP 神经网络在预测算法中具有很大的优点，首先它可以通过不断地修改权值来增加模型的准确性，其次具有高度的容错性，即使部分神经元损伤也不会破坏整体，网络的高度连接意味着少量的误差可能不会出现严重的后果。然而，神经网络的建立需要大量的数据来进行模型的训练，以确保模型的准确性。因此，通过 FEKO 电磁仿真软件，对标签的长度及植入

(上接第 165 页)

表 6 服务器端调度算法的数据遗漏比率(高度负载) %

分布	具有 FIFO 云电子书	具有 LaSA 的云电子书
正太分布	86.2	67.7
泊松分布	89.4	72.0

表 7 服务器端调度算法的数据遗漏比率(中度负载) %

分布	具有 FIFO 云电子书	具有 LaSA 的云电子书
正太分布	26.7	16.1
泊松分布	27.2	14.2

表 8 服务器端调度算法的数据遗漏比率(轻度负载) %

分布	具有 FIFO 云电子书	具有 LaSA 的云电子书
正太分布	15.8	3.0
泊松分布	18.1	6.1

4 结论

本文提出了一种综合电子书系统，即 Android 系统上的云电子书系统，该系统可提供文件转化、数据归档和向量图像表示功能。为了有效地优化云电子书系统，提出了一种应用于云电子书系统的多级优化框架。在图形描述、计算性能等多个方面进行了优化。与其他几种系统和类库相比，明显提升了整体性能。

由于许多编程人员利用 GPU 计算的优势来提高嵌入式环境中系统类库的性能，而 Open VG 是一种性能较差的嵌入平台实现 2D 向量图形标准接口，后期针对特定平台考虑用 GPU 对其进行改善。

参考文献:

[1] Larson L C. Digital readers: the next chapter in E-Book reading

环境进行了模拟仿真，从而得到神经网络建模所需要的训练数据。通过仿真建模的方式比起实际操作起来更加方便简单，并且具有可行性。对以后不同型号轮胎的长距离信息采集具有一定的帮助作用。

参考文献:

[1] 张志刚. 射频识别 RFID 技术在汽车电子中的应用 [J]. 应用科技, 2012, 7.

[2] 谢溪凌, 汪俊亮, 郑卫刚. 飞翔智能轮胎的仿真设计 [J]. 研究与开发, 2012, 5.

[3] 王曙光, 董兰飞, 邬立春. RFID 轮胎标签封装设备的设计开发 [J]. 橡胶技术与装备, 2010, 36 (6).

[4] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计 [M]. 北京: 清华大学出版社, 2013.

[5] 王曙光, 董兰飞, 邬立春. RFID 轮胎标签封装设备的设计开发 [J]. 橡胶技术与装备. 2010, 36 (6): 40-42.

[6] 周品. MATLAB 神经网络设计与应用 [M]. 北京: 清华大学出版社, 2013.

[7] 郭涤, 周军. 基于 Matlab 的神经网络预测模型研究 [J]. 物流科技, 2006 (1): 125-128.

[1] and response [J]. Reading Teacher, 2010, 64 (1): 15-22.

[2] 毛香英, 郁梅, 蒋刚毅, 等. 基于结构失真分析的立体图像质量客观评价模型 [J]. 计算机辅助设计与图形学学报, 2012, 24 (8): 1047-1056.

[3] Goya C. Visualization of collecting locations based on scalable vector graphics for the specimen information software [J]. Advanced Materials Research, 2014, 642 (4): 322-331.

[4] 乐银煌. 基于学习型电子书的移动学习模式研究及其应用 [D]. 中国科学技术大学, 2014.

[5] 杨志刚, 张新兴, 庞弘毅. 电子书阅读器在国外图书馆的应用现状及存在问题 [J]. 大学图书馆学报, 2011, 29 (4): 11-17.

[6] 焦灵芝. 亚马逊电子书平台研究 [D]. 南京: 南京大学, 2013.

[7] 王芳. 电子书标准化建设的目的、现状与对策探讨 [J]. 情报科学, 2011, 27 (6): 953-956.

[8] Sans V, Diaz J, Implementing a multimedia application on iphone: a case study [A]. 2011 IEEE 14th International Conference on Computational Science and Engineering (CSE), 2011: 233-238.

[9] 丁建飞. 基于语义的电子书交互阅读 [D]. 北京: 北京交通大学, 2013.

[10] Kim D, Cha K, Chae S I. A high-performance Open VG accelerator with dual-scanline filling rendering [J]. IEEE Transactions on Consumer Electronics, 2008, 54 (3): 1303-1311.

[11] Kim D, Cha K, Soo-Ik C. Adaptive Scanline Filling Algorithm for Open VG 2D Vector Graphics Accelerator. [J]. Ieice Transactions on Information & Systems, 2009, 92 (7): 1500-1502.

[12] Jackson W. WatchFaces Vector Design: Using Vector Graphics for WatchFaces [M]. Pro Android Wearables. Apress, 2015.

[13] 杨瑛, 刘文文, 吴方贵. 基于 GPU 的可视化测量仪器软件设计 [J]. 计算机测量与控制, 2016, 24 (8): 150-153.

[14] 姚卫国, 张东波. 基于 Hadoop 分布式平台的 Web 文本关键词提取方案 [J]. 湘潭大学自然科学学报, 2016, 38 (2): 79-83.

[15] Liu J, Wu T, Lin M W, et al. An Efficient Job Scheduling for MapReduce Clusters [J]. International Journal of Future Generation Communication & Networking, 2015, 34 (6): 109-115.