

基于卷积神经网络的金属检测系统设计

丁沫然, 李丕丁, 谢松霖

上海理工大学健康科学与工程学院, 上海

收稿日期: 2024年8月4日; 录用日期: 2024年9月2日; 发布日期: 2024年9月9日

摘要

为了解决传统金属检测系统受产品效应影响下误报率高、检测灵敏度低, 检测失效等问题, 本文通过参考经典卷积神经网络, 提出一种专用于金属检测的MD-net卷积神经网络二分类模型, 并设计了基于该分类模型的金属检测系统。该系统的下位机以FPGA为核心, 实现了金属信号的测量和预处理。PC上位机在Windows系统环境下, 实现了金属信号的特征提取和卷积神经网络的二分类识别。试验结果表明, 即使在较强产品效应影响下, 对于铁颗粒的最小检测精度为1.2 mm, 检测准确率可达98.92%, 该系统对金属异物具有较高的检测灵敏度和良好的检测性能。

关键词

金属检测, 卷积神经网络, 产品效应

Design of Metal Detection System Based on Convolutional Neural Network

Moran Ding, Piding Li, Songlin Xie

School of Health Sciences and Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Aug. 4th, 2024; accepted: Sep. 2nd, 2024; published: Sep. 9th, 2024

Abstract

In order to solve the problems of traditional metal detection systems such as high false alarm rate, low detection sensitivity, and detection failure due to product effects, this paper proposes an MD-net convolutional neural network dedicated to metal detection by referring to the classic convolutional neural network. Based on the MD-net binary classification model, this paper designs a metal detection system for detecting metal foreign objects in food. The lower computer of this system uses FPGA as the core to realize the measurement and preprocessing of metal signals. The PC host computer

realizes the feature extraction of metal signals and the two-class recognition of convolutional neural networks in the Windows system environment. The test results show that even under the influence of strong product effects, the minimum detection accuracy for iron particles is 1.2 mm, and the detection accuracy can reach 98.92%. The system has high detection sensitivity and good detection performance for metal foreign matter.

Keywords

Metal Detection, Convolutional Neural Network, Product Effect

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着传感器技术蓬勃发展以及规模的不断扩大,金属检测识别技术在安全检查、工业制造、环境保护、资源探测、食品安全等领域有着极其重要的研究意义和广泛的应用前景,例如公共场所的安检门、军工领域的扫雷装置、食品行业的金属异物检测机[1] [2]。金属异物检测方法主要分为电磁检测和 X 射线检测两类[3]。在食品安全领域,相较于电磁检测技术, X 射线对含水量高的产品和镀铝包装产品有更好的检测能力[4],但其成本高昂,且对人体有辐射伤害。而电磁检测技术具有灵敏度高、无辐射、成本低廉等特点,广泛应用于食品金属异物检测领域[5]。

在金属异物电磁检测技术领域, Ehsan Najafi 等人提出一种基于多带 Chirp 信号(MLC)的新型感应平衡金属探测器,提升了检测深度的同时还可以区分金属类别[6]。Jakub Svatoš 等人使用多谱 - 线性扫频作为信号激励,在频率范围 50 至 1000 kHz 获得更多的有效信息,从而显著降低了误检率[7]。Hernan Haimovich 等人在不更改现有硬件的情况下,提出了一种能够通过考虑检测信号的形状来提高金属检测灵敏度的算法,优化了检测流程[8]。在金属异物检测设备生产行业,国外的金属检测设备较为先进,美国 Thermo Fisher 公司的设备实现了线圈实时自平衡功能;日本 Anritsu 公司使用双频检测技术,提高了金属的检测精度;英国 Mettler Toledo 公司利用多频同步调制技术,增强了设备对产品信号的抑制能力。而国内的检测技术多是基于单频调谐技术,其温度及机械稳定性差,主要对信号的幅值信息进行处理,检测性能与国外设备差距很大。

神经网络是一种受人类大脑神经元运作而启发的计算模型[9],通过模拟人脑神经元的连接和学习方式对数据进行分析 and 分类,广泛应用于自然语言处理、图像识别、语音识别等领域[10]。本文旨在研究一种基于卷积神经网络(CNN)的金属检测系统,通过整合先进的深度学习算法与优化的金属检测系统设计,全面提升金属检测的性能和应用效果。

2. 金属异物检测系统总体方案设计

金属检测系统总体方案如图 1 所示,基于金属检测系统的实时性及高检测精度前提下,考虑到神经网络的运行资源需求,选择 Xilinx 公司的 K7-UltraScale 系列 FPGA 作为系统的主控芯片。本系统主要包括平衡线圈传感器、信号激励部分、前置滤波放大部分、A/D 采集部分、数字锁定放大器部分、PC 上位机与 MD-net 神经网络算法处理模块等。金属异物穿过金属检测传感器,平衡状态下的空间电磁场被破坏,通过系统对异常信号的幅值和相位信息进行解析,实现对金属异物的检测。




Figure 1. Overall scheme of metal detection system
图 1. 金属检测系统总体方案

本系统的金属检测传感器采用平衡线圈传感器[11]，如图 2 所示。中间线圈作为发射线圈。两侧的线圈是接收线圈，两个接收线圈反向并联。发射线圈的正弦激励信号频率为 300 kHz。在无异常金属通过时，传感器由于变压器效应产生的感应电动势被抵消，形成接收平衡状态。当金属异物通过传感器时，平衡线圈传感器输出的信号信息不仅包含金属信号的幅度，还包含了输出信号与驱动发射线圈信号之间的相位差。输出的信号经锁定放大器正交解调，得到同相分量 I 与正交分量 Q [12]，最后再根据 I、Q 信息来判断金属异物的有无。




Figure 2. Balance coil sensor
图 2. 平衡线圈传感器

3. 系统数据的信号处理方案设计

3.1. 信号调理部分

检测的金属异物通常是体积较小的金属颗粒，产生的金属信号极其微弱，容易受环境噪声及产品效应[13]的影响，输出信号经调理电路进一步处理。在放大电路之前设计了一个 LC 并联谐振电路，谐振频

率和发射频率都为 300 kHz，实现带通滤波的同时提高了信噪比。信号调理电路如图 3 所示，放大器与接收线圈的输出端用变压器进行耦合，变压器次级并联了谐振电容实现了信号的选频及滤波。采用 AD8065 作为前置放大器，并利用反馈电阻来减少额外噪声。




Figure 3. Schematic diagram of conditioning circuit

图 3. 调理电路原理图

3.2. 锁定放大器

锁定放大器广泛应用于微弱信号的检测[14]，在金属检测中主要应用于微弱金属信号的提取，极大提高检测灵敏度与精度。传统的模拟锁定放大器通过选择特定的参考频率，利用一个正弦参考信号与输入信号相乘，再与积分器组成解调电路，从而分离出窄带信号。但是模拟锁定放大器易受限于模拟元件的精度、稳定性以及温度漂移等因素的影响，极大降低了系统的检测精度。本文使用数字锁定放大器[15]对微弱金属信号进行提取，利用数字处理实现信号的解调，克服了传统锁定放大器的缺陷，并且通过软件可调，增加了系统的灵活性。数字锁定放大器由数字乘法器、正交参考信号、数字低通滤波器组成，如图 4 所示。




Figure 4. Digital lock-in amplifier

图 4. 数字锁定放大器

将金属检测信号 $X(t)$ 定义为 $A\sin(\omega t + \varphi)$ ， $\sin \omega t$ 和 $\cos \omega t$ 共同构成了正交参考信号，输入信号与正交参考信号相乘对应的输出分别是 $r_i(t)$ 和 $r_q(t)$ ：

$$r_i(t) = \frac{A}{2} \cos \varphi - \frac{A}{2} \cos(2\omega_0 t + \varphi) \quad (1)$$

$$r_q(t) = \frac{A}{2} \sin \varphi + \frac{A}{2} \sin(2\omega_0 t + \varphi) \quad (2)$$

$r_i(t)$ 和 $r_q(t)$ 经过数字低通滤波后得到 $I(t)$ 与 $Q(t)$:

$$I(t)=\frac{A}{2}\cos(\varphi) \tag{3}$$

$$Q(t)=\frac{A}{2}\sin(\varphi) \tag{4}$$

根据式(3)、(4)即可得到输入信号 $X(t)$ 的幅度 A 与相位 φ :

$$A=2\sqrt{I^2+Q^2} \tag{5}$$

$$\varphi=\tan^{-1}\left(\frac{Q}{I}\right) \tag{6}$$

根据式(5)、(6)可求出信号的幅值与相位，其中相位 φ 是采样金属信号 $X(t)$ 与参考信号之间的相位差。

4. 金属检测算法设计

常见的金属检测设备的检测方法是判断信号的幅值是否超过阈值，然而当金属异物体积较小时，该方法对信号幅值的判断不够精确，导致检测率下降。为了解决这一问题，本系统将卷积神经网络(CNN)与金属检测相结合，通过学习大量样本数据，自动提取金属信号特征，实现高效、精确的金属检测[16]。

与传统方法不同的是，本系统不仅处理信号的幅值信息，还利用 CNN 提取和分析信号的相位信息。这种双信息处理的方法显著提高了系统对产品效应和环境噪声的抗干扰能力，使得在复杂环境中也能准确检测出微小金属异物。金属检测算法的具体流程如图 5 所示。




Figure 5. Flow chart of metal detection algorithm
图 5. 金属检测算法流程图

4.1. 信号预处理及特征提取

在金属检测信号进入神经网络训练模型前，需要尽可能提高信号的信噪比，需要对原始检测数据进行预处理及特征提取。由于产品效应的存在，金属信号淹没于产品信号之下，使得金属异物难以检测。本文采用坐标旋转法，可以有效地抑制产品信号对金属信号的干扰。图 6 为无金属卤水鸭掌数据的拟合图像，图 6 中所标出的每个数据点都分别包含了 I 分量电压值与 Q 分量电压值，设每次采集到的数据矩阵为 Y ，则第 k 个数据点为 $Y_k = [V_{ik}, V_{qk}]$ 。




Figure 6. Fitting chart of Metal free duck paw product data
图 6. 无金属的鸭掌产品数据拟合图

在使用坐标旋转算法之前，需要知道相位的旋转角度，这个旋转角度根据不同产品的平均相位来设置。取 20 次无金属卤水鸭掌的测试数据，利用最小二乘拟合来计算出产品的平均相位，拟合直线如图 6 所示。

设最小二乘拟合得到的直线为：

$$y_0 = a_0 x + b \quad (7)$$

则可以计算出检测信号的特征相位为：

$$\varphi_p = \tan^{-1}(a_0) \quad (8)$$

根据求得特征相位 φ_p ，利用式(9)可以对待检测的产品信号进行坐标旋转，旋转后得到 Y_r ：

$$Y_r = YT \quad (9)$$

其中旋转矩阵 T 定义为：

$$T = \begin{bmatrix} \cos \varphi_p & -\sin \varphi_p \\ \sin \varphi_p & \cos \varphi_p \end{bmatrix} \quad (10)$$

图 7 为产品含有 1.5 mm 铁质异物的检测信号，图 8 为该信号进行坐标旋转后的图像。将两个图像进行对比可以看出，坐标旋转后，信号的 I 分量幅值大幅减少，产品效应对金属信号的干扰变弱。




Figure 7. Duck paw product (+1.5 Fe) (Before coordinate rotation)
图 7. 鸭掌产品带有 1.5 mm 的 Fe 颗粒(坐标旋转前)




Figure 8. Duck paw product (+ $\varnothing=1.5$ Fe) (After coordinate rotation)
图 8. 鸭掌产品带有 1.5 mm 的 Fe 颗粒(坐标旋转后)

FPGA 对金检信号的解调速率为 400 Hz，每件产品经过金属检测传感器的时间约为 1.0 s，所以每次采集 400 个数据点，其中包含了产品信号以及空机信号。图 8 的数据总共有 300 个采样点，而 200 个数据点足够反映产品信号的特征，包含了检测信号的幅值及相位信息，其余数据点都是空机运行状态。所以检测数据将通过光电开关来进行规则化，截取有效的 200 个采样点，为进入神经网络模型做准备。

4.2. 基于卷积神经网络的 MD-net 分类模型

本文以经典的卷积神经网络模型 LeNet-5 [17]为参考，结合金属检测信号的相关特征，设计了专用于金属异物检测的 Metal Detection-net 网络(MD-net)，MD-net 网络结构如图 9 所示。该网络模型由四个卷积层，四个激活层，一个池化层，全连接层和输出层构成。




Figure 9. MD-net structure
图 9. MD-net 结构

(1) 输入层：在金属异物尺寸较小，且带有强产品效应的情况下，仅依靠信号幅值难以分辨金属异物，因此信号相位也作为神经网络模型的输入。

(2) 卷积层: 本文的神经网络模型是基于多卷积层设计的, 每个卷积层叠加多个卷积核对检测信号进行特征提取, 这有助于保留检测数据显著特征。MD-net 总共有四个卷积层, 分别为 c1 层、c2 层、c3 层、c4 层, 每层的卷积核个数依次为 16、32、32、64。四个卷积层后面都使用了激活函数对卷积层的输出进行非线性变换, 增强网络的表达能力。若 j 个卷积核卷积以产生 j 个不同的特征图, 即:

$$x_j^k = f\left(\sum_{i \in M_j} x_i^{k-1} \cdot W_{ij}^k + b_j^k\right) \quad (11)$$

其中, x_j^k 表示第 K 层的第 j 个特征图, W_{ij}^k 表示卷积核, M_j 表示特征量, b_j^k 为偏差量, $f()$ 是激活函数。

(3) 池化层: 在卷积层 c1 提取到特征后, 利用池化层进行下采样, 保留了信号特征的同时, 提高了计算效率。

(4) 输出层: 将提取到的特征输入到全连接层, 全连接层输出一个节点, 使用 Sigmoid 函数作为激活函数, 最后输出结果会映射到 0~1 之间。输出结果大于 0.5 的数据标记为“1”, 判定为检测到金属异物; 输出结果小于等于 0.5 标记为“0”, 判定为无金属异物。

4.3. MD-net 模型分析

本文所设计的 ME-net 的网络相关参数如表 1 所示。模型的训练在 Windows10 专业版操作系统上进行, CPU 型号为 AMD Ryzen-5 2600, 运行内存 32 GB, GPU 为 RTX 3060, 通过 Python 和 PyTorch 深度学习框架实现。数据来源于金属检测机对产品的测试信号, 样本总容量为 3000, 其中训练数据有 1500 (产品、产品 + 金属各占 50%), 测试数据样本为 1500 (产品、产品 + 金属各占 50%)。

Table 1. MD-net network model parameters

表 1. MD-net 网络模型参数

层类型	核数量	核尺寸	步长	填充	输出
输入层	—	—	—	—	200×2
卷积层_1	16	1×3	1	Same	$200 \times 2 \times 16$
ReLU_1	—	—	—	—	$200 \times 2 \times 16$
池化层_1	—	1×2	2	—	$100 \times 1 \times 16$
卷积层_2	32	1×3	1	Same	$100 \times 1 \times 32$
ReLU_2	—	—	—	—	$100 \times 1 \times 32$
卷积层_3	32	1×3	1	Same	$100 \times 1 \times 32$
ReLU_3	—	—	—	—	$100 \times 1 \times 32$
卷积层_4	64	1×3	1	Same	$100 \times 1 \times 64$
ReLU_4	—	—	—	—	$100 \times 1 \times 64$
全连接层	—	—	—	—	1
输出层	—	—	—	—	1

通过准确率(Acc)、召回率(Recall)、精确率(Precision)和 F1 分数四个指标, 对 MD-net 网络模型的性能进行评估, 其计算公式如下:

$$\text{Acc} = \frac{T_p + T_n}{T_p + F_n + F_p + T_n} \times 100\% \quad (12)$$

$$\text{Recall} = \frac{T_p}{T_p + F_n} \times 100\% \quad (13)$$

$$\text{Precision} = \frac{T_p}{T_p + F_p} \times 100\% \quad (14)$$

$$F1 = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \times 100\% \quad (15)$$

其中, T_p 表示正确预测为带金属异物的样本数, T_n 表示正确预测为无金属异物的样本数, F_p 表示错误预测带有金属异物的样本数, F_n 表示错误预测不带金属异物的样本数。

图 10 是模型的准确率 - 损失值与迭代次数之间的关系图, 测试的产品为卤水鸭掌, 在 MD-net 网络模型训练过程中, 损失值逐步下降, 准确率逐步上升, 在迭代了 45 次以后, 损失值几乎不再发生变化。到了第 50 次迭代, 网络模型趋于稳定, 且分类性能良好, 无过拟合现象出现。




Figure 10. Relationship curve of accuracy-loss value-iteration times
图 10. 准确率 - 损失值 - 迭代次数关系曲线

另外, 基于 MD-net 模型, 我们又训练了其他产品的测试集数据, 得到了如表 2 所示的 MD-net 模型性能评估参数。从表中的数据可以看出, 不同种类的产品所训练出的 MD-net 网络, 对金属异物的分类效果有细微差别。由于鸭掌含有骨头、盐水, 以及酸菜含盐量高, 产品效应大, 因此分类效果最好的是面包, F1 分数达到了 95.00%。结果表明, 该模型在金属检测方面展示出了优异的性能。

Table 2. MD-net model performance evaluation parameters
表 2. MD-net 模型性能评估参数

产品种类	准确率 Acc.	召回率 Recall	精确率 Precision	F1
卤水鸭掌	92.00%	91.45%	92.38%	91.91%
酸腌菜	93.75%	93.96%	93.50%	93.73%
干面包	95.00%	95.47%	94.52%	95.33%

5. 系统试验及分析

根据以上金属检测系统方案完成硬件电路, 并且在 PC 端上位机实现金属异物检测算法的部署。金属检测传感器的尺寸为 470 mm × 225 mm (宽 × 高), 信号激励频率为 300 kHz; 产品传输装置来自于上海晶默电子科技有限公司, 传送带速度为 22 m/min; PC 端配置是华硕电脑, 操作系统为 Windows 10 64 位旗舰, 第 12 代酷睿 i7 CPU, 内存 32 GB; 试验金属异物种类方面, 用塑料卡片塑封了直径为 0.8~3.0 mm 的铁质(Fe)颗粒、1.2~3.0 mm 的不锈钢(SUS)颗粒和 1.0~3.0 mm 的无铁合金(No-Fe), 覆盖了食品加工流程中常见的金属异物。在系统检测之前, 要对各产品进行模型训练, 训练样本总容量为 3000, 其中训练

数据有 1500 (产品、产品 + 金属各占 50%)，测试数据样本为 1500 (产品、产品 + 金属各占 50%)，训练模型参数与表 1 一致。

5.1. 无产品的单独金属检测

对应产品的网络模型训练完成后将部署在 PC 上位机中。首先进行在不带产品情况下的金属检测，无产品效应的影响，可以直接反映了系统对单独金属的检测灵敏度。不同种类及尺寸的金属在传送带上重复通过 100 次，检测的准确率如表 3 所示。

Table 3. Accuracy of individual metal testing

表 3. 单独金属测试的准确率

种类/尺寸(mm)	0.8	1.0	1.2	1.5	2	2.5	3.0
无金属	100%	100%	100%	100%	100%	100%	100%
铁(Fe)	97%	99%	100%	100%	100%	100%	100%
不锈钢(SUS)	—	—	96%	98%	100%	100%	100%
无铁合金(No-Fe)	—	96%	99%	100%	100%	100%	100%

根据表 3 所展示的单独金属测试准确率可知，本系统所实现的金属检测灵敏度符合国标 GB/T25345-2010 要求，检测灵敏度与国标对比如表 4 所示。

Table 4. Single metal detection sensitivity

表 4. 单金属检测灵敏度

金属种类	国标要求检测尺寸	本系统检测最小尺寸	结论
Fe	1.2 mm	0.8 mm	合格
SUS	1.5 mm	1.2 mm	合格
No-Fe	1.5 mm	1.0 mm	合格

5.2. 带产品的金属检测

金属检测的测试产品选取了在实际应用中比较典型的几类产品，具有代表性。干面包几乎不含水，无盐；酸腌菜含水较少，含盐量最高；铝膜外包装的辣条体积小、铝膜产生的产品效应极强；卤水鸭张的含盐量较高，水分含量高，骨头密度大，产生的产品效应最强。

我们把不同产品数据集训练后的模型分别部署在 PC 上位机，然后开始对不同产品的金属检测灵敏度进行测，以寻找本系统能稳定检测到的最小金属颗粒尺寸。不同产品、不同异物的测试次数都限制为 300 次。不同产品金属灵敏度的测试结果如表 5 所示。

Table 5. Sensitivity of metal detection for different types of products

表 5. 不同产品的金属检测灵敏度

产品/金属种类	Fe	SUS	No-Fe
干面包	$\varnothing = 0.8 \text{ mm}$	$\varnothing = 1.5 \text{ mm}$	$\varnothing = 1.2 \text{ mm}$
酸腌菜	$\varnothing = 1.2 \text{ mm}$	$\varnothing = 2.0 \text{ mm}$	$\varnothing = 1.5 \text{ mm}$
辣条	$\varnothing = 1.5 \text{ mm}$	$\varnothing = 3.0 \text{ mm}$	$\varnothing = 3.0 \text{ mm}$
卤水鸭掌	$\varnothing = 1.5 \text{ mm}$	$\varnothing = 2.5 \text{ mm}$	$\varnothing = 2.5 \text{ mm}$

从表 5 中可以得出以下结论：干面包的产品效应最低，检测灵敏度最高；因为铝膜包装的存在，产品辣条受到产品效应的影响最大，检测灵敏度最低。综合上述几类产品来看，本系统对铁(Fe)异物的检测

效果最好，而对于不锈钢(SUS)和非铁金属(No-Fe)的检测效果相对较差。因为 Fe 的电导率小，电导率越小，电流通过介质的阻力越大，传感器接收到的产品效应信号越弱，所以传感器的检测灵敏度最高。同理，No-Fe 的检测灵敏度要优于 SUS。试验完成后，得到 MD-net 模型对不同种类金属的平均识别准确率如表 6 所示。

Table 6. The average recognition rate of different types of metals in each product
表 6. 各产品不同种类金属的平均识别率

产品/金属种类	Fe	SUS	No-Fe
干面包	99.74%	99.12%	99.45%
酸腌菜	98.92%	95.33%	96.71%
辣条	90.76%	83.45%	89.92%
卤水鸭掌	92.66%	89.73%	90.84%

6. 结论

传统的金属检测方法是判断检测信号的幅度是否超过阈值，但此类方法检测灵敏度低、误报率较高，对金属异物的检测率低。针对以上问题，本系统采用经典的金属检测装置，把卷积神经网络与金属异物检测技术相结合，设计了 MD-net 模型对金属检测信号实现自动分类，实现金属异物的高精度检测。试验结果表明，无产品效应情况下，本系统可检测的 Fe、SUS、No-Fe 颗粒的最小直径分别为 0.8 mm、1.5 mm、1.2 mm；当面对强产品效应的产品时，金属异物的最小检测直径为 1.2 mm，识别准确率可达 98.92%，表现出了较好的检测性能。MD-net 卷积神经网络模型通过学习金属信号的波形数据及相关特征，提高了系统对产品信号和金属信号的分辨能力。另外，本系统检测的对象均为单颗粒金属异物，且产品效应的影响依旧很大，对于特殊产品(如含有铝膜包装的辣条、含有骨头的鸭掌)的平均识别率不高，检测系统还需要进一步的优化和完善，以适应多种产品的金属异物检测。

参考文献

- [1] 王伟. 金属探测器原理及其应用[J]. 矿冶, 1996(4): 78-84.
- [2] 刘淑琴. 智能型金属探测器研究[D]: [硕士学位论文]. 南昌: 南昌大学, 2005.
- [3] 靳欣欣, 潘立刚, 王冬. 食品中异物种类来源及检测技术评述[J]. 食品安全质量检测学报, 2016, 7(7): 2803-2808.
- [4] 韩平, 潘立刚, 马智宏, 等. X 射线无损检测技术在农产品品质评价中的应用[J]. 农机化研究, 2009, 31(10): 6-10.
- [5] 田昨非. 针对涡流效应的信号检测及其在金属检测中的应用[D]: [硕士学位论文]. 成都: 电子科技大学, 2019.
- [6] Najafi, E., Hasanzadeh, S. and Kheradmandan, K. (2022) Induction Balance Metal Detector Using Multi-Level Chirp Signal. 2022 13th Power Electronics, Drive Systems, and Technologies Conference (PEDSTC), Tehran, 1-3 February 2022, 479-483. <https://doi.org/10.1109/pedstc53976.2022.9767474>
- [7] Svatoš, J., Vedral, J. and Fexa, P. (2011) Metal Detector Excited by Frequency-Swept Signal. *Metrology and Measurement Systems*, **18**, 57-68. <https://doi.org/10.2478/v10178-011-0006-3>
- [8] Haimovich, H., Marelli, D. and Sarlinga, D. (2020) A Signal Processing Method for Metal Detection Sensitivity Improvement in Balance-Coil Metal Detectors for Food Products. 2020 IEEE International Conference on Industrial Technology (ICIT), Buenos, 26-28 February 2020, 645-651. <https://doi.org/10.1109/icit45562.2020.9067312>
- [9] 蹇宇澄, 刘昭策. 深度学习的实现与发展——从神经网络到机器学习[J]. 电子技术与软件工程, 2017(11): 30-31.
- [10] 赵崇文. 人工神经网络综述[J]. 山西电子技术, 2020(3): 94-96.
- [11] 邱松. 感应平衡式金属检测系统设计及实现[D]: [硕士学位论文]. 成都: 电子科技大学, 2019.
- [12] 吴云树, 汪浩. 基于 FPGA 的数字下变频技术研究[J]. 国外电子测量技术, 2019, 38(11): 113-118.
- [13] Huang, J. 解决管道应用中的产品效应[J]. 食品安全导刊, 2020(31): 42-43.

-
- [14] 时宣华. 锁定放大器的微弱信号检测装置设计[J]. 常州工学院学报, 2021, 34(5): 28-32.
 - [15] 李昌, 周松斌. 基于数字锁相放大器的电涡流位移传感器[J]. 电子器件, 2022, 45(2): 445-449.
 - [16] Li, Z., Liu, F., Yang, W., Peng, S. and Zhou, J. (2022) A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, **33**, 6999-7019.
<https://doi.org/10.1109/tnnls.2021.3084827>
 - [17] Wang, T., Lu, C., Shen, G. and Hong, F. (2019) Sleep Apnea Detection from a Single-Lead ECG Signal with Automatic Feature-Extraction through a Modified Lenet-5 Convolutional Neural Network. *PeerJ*, **7**, e7731.
<https://doi.org/10.7717/peerj.7731>