

Gépi hallás alkalmazása

SCARA robotos csomagológép cellában: akusztikai anomáliadetektálás és OEE optimalizálás gépi tanulással

ARADI Attila^{1,2}, Dr. TAKÁCS Péter³, Dr. VARGA Attila Károly²

¹ ION-technik Kft., Miskolci Egyetem Aradi.Attila@gmail.com

² Miskolci Egyetem, Attila.Varga@uni-miskolc.hu

³ HUN-REN Balatoni Limnológiai Kutatóintézet, ION-technik Kft, takacs.peter@blki.hu

Abstract

The study investigates the integration of machine hearing technology in SCARA robot-based industrial packaging machine cells. The proposed deep SVDD-based anomaly detection system is expected to achieve an accuracy above 95%, while an 8-12% improvement in the OEE metric is forecasted. Implementation costs are 60-70% lower compared to machine vision-based solutions. The concept outlines the system architecture, expected performance metrics, and implementation considerations.

Keywords: machine hearing, SCARA robot, anomaly detection, machine learning, artificial intelligence, OEE

Kivonat

A tanulmány a gépi hallás technológia integrációját vizsgálja SCARA robotos ipari csomagológép cellákban. A javasolt deep SVDD alapú anomáliadetektálási rendszer várhatóan 95% feletti pontosságot érhet el, miközben az OEE mutató 8-12%-os javulása prognosztizálható. Az implementációs költségek 60-70%-kal alacsonyabbak a gépi látás alapú megoldásoknál. A koncepció bemutatja a rendszerarchitektúrát, várható teljesítménymutatókat és implementációs szempontokat.

Kulcsszavak: gépi hallás, SCARA robot, anomáliadetektálás, gépi tanulás, mesterséges intelligencia, OEE, Ipar 4.0

1. BEVEZETÉS

Az Ipar 4.0 keretében az ipari robotok intelligens monitoring rendszerei kritikus fontosságúak. A SCARA robotok széles körű alkalmazása a csomagolási folyamatokban indokoltá teszi költséghatékony állapotfigyelő rendszerek fejlesztését [1]. Ezek a robotok jellemzően $\pm 0.01-0.05$ mm ismétlési pontossággal és 5-10 m/s sebességgel működnek [2].

Nisar és társai [3] 52 publikációt elemezve megállapították, hogy az akusztikai anomáliadetektálás még kevésbé elterjedt a robotikában, jelentős potenciált hordozva. Togami és társai [4] kimutatták, hogy zajos ipari környezetben az akusztikai módszerek robusztusabbak a gépi látásnál, képesek rejtett hibák detektálására is.

A DCASE 2020 Challenge [5] mérföldkő volt az ipari akusztikai anomáliadetektálásban, felügyelet nélküli gépi tanulás paradigmát alkalmazva. A MIMII adatkészlet [6] négy géptípus 48 kHz-es hanganyagával objektív összehasonlítását tesz lehetővé.

Verma és Kumar [7] deep SVDD módszere egyosztályos klasszifikációval dolgozik:

$$\min_{W,c} \frac{1}{n} \sum_{i=1}^n |\phi(x_i; W) - c|^2 + \lambda \cdot \Omega(W)$$

Das és Dülger [8] SCARA robot dinamikai modellje figyelembe veszi a mechanikai komponensek hatásait:

$$M(\theta)\ddot{\theta} + C(\theta, \dot{\theta})\dot{\theta} + G(\theta) + F(\dot{\theta}) = \tau$$

Tao és társai [9] szerint a rezgések spektrális karakterisztikája értékes információt hordoz a mechanikai állapotról, ami az akusztikai monitoring alapja.

2. ANYAGOK ÉS MÓDSZEREK

A moduláris rendszer központi eleme az peremhálózati számítás (edge computing) platform, amely valós időben dolgozza fel az akusztikai adatokat. A mikrofonok stratégiai elhelyezése kritikus: primer szenzorok a robot közelében, szekunder szenzorok a munkaterület határain, referencia szenzor a háttérzaj kompenzációjára. A DSP előfeldolgozó valós idejű jelfeldolgozást végez, míg az ML modul a deep SVDD algoritmust futtatja. A PLC interfész biztosítja a robot vezérlővel való kapcsolatot, lehetővé téve azonnali beavatkozást.

Az optimális szenzor elhelyezés az akusztikai tér modellezésével történik:

$$p(r, t) = \sum_{i=1}^N \frac{A_i}{4\pi r_i} e^{j(\omega t - kr_i + \phi_i)}$$

A SCARA robot specifikus geometriája alapján a következő elhelyezési konfiguráció optimális: Primer mikrofon array (4 db): Pozíció: A robot alapjától 0.5-1.0 m távolságra, 120°-os szögeloszlásban. Magasság: A robot középvonalával egy síkban (tipikusan 1.2-1.5 m) Orientáció: 45°-os dőlésszög a robot középpontja felé Típus: Kardiod karakterisztika a háttérzaj elnyomására. Szekunder monitoring mikrofonok (2-3 db). Pozíció: Munkaterület sarkaiban, 2-3 m távolságra. Funkció: Környezeti zaj referencia és munkaterület események detektálása. Típus: Omnidirekcionális, széles frekvenciatartomány (20 Hz - 20 kHz). Közel-mező szenzor (1 db): Pozíció: Közvetlenül az end-effector közelében (10-20 cm) Funkció: Pick-and-place műveletek precíz monitoringja. Típus: MEMS mikrofon, frekvenciás válasz 40 kHz-ig

2.1. Akusztikai jellemzők kinyerése

A jellemzőkinyerés többszintű: időtartománybeli (RMS energia, zérusátmeneti gyakoriság), frekvenciatartománybeli (spektrális súlypont) és cepstrális (MFCC) jellemzők. Az MFCC számítás:

$$\text{MFCC}_n = \sum_{m=1}^M \log(E_m) \cos \left[\frac{n(m-0.5)\pi}{M} \right]$$

Ota és Unoki [10] Hangszín-metrikák alkalmazásával (spektrális fényesség, hangérdesség, hangélesség) a pontosság 0.97 fölé növelhető. Li és társai [11] IMS spektrogramja egyesíti a log-Mel és SincNet előnyeit.

2.2. Anomáliadetektálás

A háromszintű detektálás gyors előszűrésből, ML-alapú klasszifikációból és kontextuális validációból áll. Az adaptív küszöbérték:

$$\tau(t) = \mu_{\text{norm}} + \alpha \cdot \sigma_{\text{norm}} \cdot f(\text{SNR}, t)$$

2.3. Várható teljesítmény

Várható teljesítmény összehasonlítás

Paraméter	Gépi Hallás	Gépi Látás
Detektálási pontosság	94-97%	85-90%
Válaszidő	30-60 ms	150-250 ms
Térbeli lefedettség	360°	60-120°
Rejtett hibák detektálása	Igen	Nem

Az OEE javulás komponensei: rendelkezésre állás +7-10% (prediktív karbantartás), teljesítmény +2-4% (optimalizált üzemeltetés), minőség +1-2% (korai hibadetektálás). Összességében 8-12% OEE javulás várható.

2.4. Költség-haszon elemzés

Relatív költségek (gépi látás = 100%)		
Költségelem	Gépi Hallás	Gépi Látás
Hardver	30-40%	100%
Telepítés	50-60%	100%
Karbantartás/év	20-30%	100%
TCO (5 év)	35-45%	100%

2.5. Technikai kihívások

Az ipari környezet 75-85 dB háttérzaja adaptív szűrést igényel. A Wiener-szűrő optimalizálja a jel-zaj viszonyt:

$$H(f) = \frac{S_{xx}(f)}{S_{xx}(f) + S_{nn}(f)}$$

A valós idejű feldolgozás peremhálózati számítással (edge computing), optimalizált algoritmusokkal (STFT) és párhuzamos architektúrával valósítható meg. A nyálábformálás technika több mikrofonnal irányított érzékenységet biztosít.

2.6. Integráció

A robot vezérlővel OPC UA, EtherCAT vagy Modbus TCP protokollokon keresztül kommunikál a rendszer. A SCADA/MES integráció REST API és MQTT protokollokkal történik, a historikus adatok SQL adatbázisban tárolódnak.

2.7. Alkalmazási területek és skálázhatóság

A rendszer adaptálható szerelősorok felvétel és lehelyezés („pick-and-place”) műveleteire és csomagoló robotok felvétel és lehelyezés darabkezelés ütközés-detektálására. A horizontális skálázás költséghatékonysága:

$$C_{\text{total}} = C_{\text{base}} + n \cdot C_{\text{sensor}} + \log(n) \cdot C_{\text{compute}}$$

A vertikális skálázás prediktív karbantartást (RUL becslés), folyamat optimalizálást és minőségbiztosítást foglal magába. A hibrid megközelítések audio-vizuális szenzorfüziót alkalmaznak a megbízhatóság növelésére.

3. EREDMÉNYEK

A gépi hallás alapú anomáladetektálás jelentős előnyöket kínál SCARA robotos alkalmazásokban. A 94-97%-os detektálási pontosság, 8-12%-os OEE javulás és 60-70%-os költségmegtakarítás vonzó üzleti lehetőséget teremt. A szükséges technológiák rendelkezésre állnak, az integráció megoldható. A rendszer skálázhatósága és adaptálhatósága biztosítja a hosszú távú értékteremtést. A fejlett gépi tanulási technikák közül a kevés mintás tanulás (few-shot learning) lehetővé teszi a gyors alkalmazkodást új hibatípusokhoz minimális tanítóadat mellett. A folyamatos tanulás (continual learning) paradigma úgy képes új ismeretek elsajátítására, hogy közben megőrzi a korábban tanult tudást, elkerülve a katasztrofális felejtés jelenségét. A magyarázható mesterséges intelligencia (explainable AI) technikák alkalmazása pedig átláthatóvá és értelmezhetővé teszi a rendszer döntési folyamatait, ami kritikus fontosságú az ipari elfogadottság szempontjából. Az ipari szabványosítás terén az ISO 13374 és IEC 61508 szabványokhoz illeszkedés szükséges.

KÖSZÖNETNYILVÁNÍTÁS

Szeretnénk köszönetet nyilvánítani az ION-technik Kft-nek., az ION Alkalmazott Kutatási NP Kft.-nek és a KDP Kooperatív Doktori Program, Kulturális és Innovációs Minisztérium, Nemzeti Kutatási, Fejlesztési és Innovációs Alapnak.

IRODALMI HIVATKOZÁSOK

- [1] Chettibi, T., et al. (2004). Minimum cost trajectory planning for industrial robots. *Eur. J. Mech. A/Solids*, 23(4), 703-715.
- [2] Gosselin, F., et al. (2014). Design of an economical SCARA robot for industrial applications. *IEEE ICRoM*, 932-937.
- [3] Nisar, S., et al. (2022). Detection of Mechanical Failures in Industrial Machines. *Sensors*, 22(10), 3888.
- [4] Togami, M., et al. (2021). Acoustic Anomaly Detection in Noisy Factory Environments. *Electronics*, 10(19), 2329.
- [5] Koizumi, Y., et al. (2020). DCASE2020 challenge task2: Unsupervised anomalous sound detection. *Proc. DCASE2020*, 81-85.
- [6] Purohit, H., et al. (2019). MIMII Dataset: Sound dataset for malfunctioning industrial machines. *Proc. DCASE2019*, 209-213.
- [7] Kilickaya, S., et al. (2024). Audio-based Anomaly Detection in Industrial Machines Using Deep One-Class Support Vector Data Description. *arXiv preprint arXiv:2412.10792*.
- [8] Das, M. T., & Dülger, L. C. (2005). Mathematical modelling of a SCARA robot. *Simul. Model. Pract. Theory*, 13(3), 257-271.
- [9] Tao, W. M., et al. (2006). Residual vibration analysis for SCARA robots. *Int. J. Intell. Control Syst.*, 11(2), 97-105.
- [10] Ota, Y., & Unoki, M. (2023). Anomalous sound detection using timbral metrics. *IEEE Access*, 11, 72297-72307.
- [11] Li, Y., et al. (2023). IMS Spectrogram and ES-MobileNetV3 Network. *Appl. Sci.*, 13(23), 12912.
- [12] Davis, S., & Mermelstein, P. (1980). Comparison of parametric representations. *IEEE Trans. ASSP*, 28(4), 357-366.
- [13] Subhashini, P., et al. (2016). Parametric Optimization of SCARA Robot. In *CAD/CAM, Robot for Deburring Of Rectangular Paths*