

UPORABA UMETNE INTELIGENCE PRI KONČNI KONTROLI KVALITETE ELEKTROMOTORJEV

Jernej Mlinarič

Izveček:

Članek obravnava sodobne pristope h končni kontroli kakovosti (angl. End of Line – EoL) elektromotorjev z uporabo umetne inteligence. EoL predstavlja zadnjo stopnjo preverjanja izdelka v proizvodnem procesu. Predstavljene so metode strojnega učenja (angl. Machine Learning), ansambelski modeli (angl. Ensembles), prenos znanja (angl. Transfer Learning) in nevronske mreže za analizo vibracijskih in zvočnih signalov, ki poenostavijo diagnostične postopke, zmanjšajo odvisnost od ekspertnega znanja ter izboljšajo prilagodljivost industrijskih EoL-sistemov. Rezultati uporabe opisanih metod kažejo na večjo robustnost diagnostike in krajši čas uvajanja novih tipov elektromotorjev v proizvodnjo.

Ključne besede:

končna kontrola kakovosti, elektromotorji, strojno učenje, umetna inteligenca, prenos znanja, nevronske mreže, vibracije, zvok

1 Uvod

Elektromotorji sodijo med najbolj množične industrijske izdelke. Vgrajeni so v gospodinske aparate, orodja, vozila in številne druge sisteme, kjer se od njih pričakuje zanesljivo in dolgotrajno delovanje. Zaradi velikih proizvodnih količin je že majhen delež napak lahko vir visokih stroškov, zato je 100 odstotna končna kontrola kakovosti (t. i. End of Line, EoL) nepogrešljiv del sodobnih proizvodnih linij.

Tradicionalni EoL-sistemi temeljijo na natančno definiranih testnih postopkih, obsežni obdelavi signalov ter na strokovno določenih pravilih in pragovih. Takšen pristop je zanesljiv, a hkrati kompleksen, slabo prilagodljiv novim variantam izdelkov in močno odvisen od izkušenih strokovnjakov. V zadnjem desetletju se zato v industriji vse bolj uveljavlja uporaba metod umetne inteligence in strojnega učenja, ki obetajo večjo avtomatizacijo, prilagodljivost in učinkovitost.

V članku sta predstavljena razvoj in uvedba metod strojnega učenja ter globokega učenja za končno kontrolo kakovosti brezkrtačnih enosmernih elektromotorjev (BLDC), ki temelji na realnih industrij-



Slika 1 : Primer modularnega EoL diagnostičnega sistema

skih podatkih in izkušnjah iz proizvodnega okolja. *Slika 1* prikazuje modularni EoL diagnostični sistem iz realnega industrijskega okolja.

2 Klasičen EoL-sistem: zanesljiv, a neprilagodljiv


Sodobni EoL-sistemi za elektromotorje so praviloma sestavljeni iz več diagnostičnih celic. Vsakemu motorju se med kratkim testnim tekom izmerijo električne veličine, hitrosti vrtenja, vibracij in zvoka. Iz zajetih signalov se z uporabo signalno procesnih metod (filtriranje, FFT, izračun RMS-vrednosti ipd.) izračuna več numeričnih značilk.

Jernej Mlinarič, mag. inž., Inštitut Jožef Stefan, Ljubljana



© The Authors 2026. CC-BY 4.0

<https://doi.org/10.5545/Ventil-32-2026-1.19>



Slika 2 : Shematski prikaz delovanja klasičnega EoL diagnostičnega sistema

Na njihovi podlagi sistem preveri, ali posamezne vrednosti ležijo znotraj vnaprej določenih mej. Če so vsi pogoji izpolnjeni, je motor ocenjen kot dober, sicer kot slab. V primeru manjkajočih meritev je motor označen kot nedefiniran. Ključna slabost takšnega pristopa je, da:


- ▶ zahteva veliko število značilk in s tem veliko pragov,
- ▶ vsebuje redundantne ali malo informativne značilke,
- ▶ je nastavitev pragov dolgotrajna in močno odvisna od ekspertnega znanja,
- ▶ se slabo prilagaja novim tipom ali variantam motorjev.

To se posebej pokaže v fazah zagona proizvodnje ali pri uvajanju novih izdelkov, ko zgodovinskih po-

datkov še ni dovolj. Slika 2 prikazuje osnovne tri korake delovanja klasičnega EoL diagnostičnega sistema. V prvem koraku se zajamejo merilni signali elektromotorja, kot so vibracije, zvok in električne veličine, ki se v drugem koraku obdelajo in pretvorijo v numerične značilke. V tretjem koraku se te značilke primerjajo z vnaprej določenimi pragovi, na podlagi česar sistem sprejme končno odločitev o kakovosti izdelka.

3 Strojno učenje kot nadgradnja ekspertnega znanja

Prvi korak k večji avtomatizaciji EoL-kontrole je bila uporaba klasičnih metod nadzorovanega strojnega učenja, kot so odločitvena drevesa, na-



Slika 3 : Shema strojnega učenja, uporabljena v [1]

ključni gozdovi, bagging in gradient boosting. Gre za tako imenovane ansambelske modele, ki združujejo več osnovnih klasifikatorjev v enoten klasifikacijski model. Te metode omogočajo dve ključni izboljšavi:

1. Samodejno izbiro relevantnih značilk – modeli iz velikega nabora določijo tiste značilke, ki največ prispevajo k pravilni klasifikaciji.
2. Samodejno določanje pragov – pragovi niso več ročno nastavljeni, temveč so implicitno vključeni v strukturo modela.

Analize na več deset tisoč realnih primerov so pokazale, da je mogoče število značilk bistveno zmanjšati (tudi za več kot polovico), ne da bi se pri tem poslabšala natančnost klasifikacije [1]. Nasprotno – poenostavljeni modeli so pogosto bolj robustni, hitrejši in lažje razložljivi.

Pomembna prednost takšnih metod je tudi njihova razložljivost (angl. Explainable AI). Odločitvena drevesa in ansambelski modeli omogočajo vpogled v to, katere značilke so ključne za odločanje, kar je v industrijskem okolju bistveno za zaupanje v sistem. *Slika 3* prikazuje postopek strojnega učenja, izveden v šestih zaporednih korakih, ki se začne z generiranjem izvirnega nabora značilk na podlagi zajema in obdelave merilnih signalov elektromo-


torjev. V nadaljevanju sledijo učenje klasifikatorjev, samodejna izbira in vrednotenje pomembnosti značilk ter postopno zmanjševanje nabora značilk na tiste, ki vsebujejo približno 95 % uporabnih informacij. V zadnjih korakih se klasifikatorji ponovno učijo na zmanjšanem naboru podatkov in se njihova učinkovitost primerja z izhodiščnimi modeli, kar omogoča oceno vpliva zmanjšanja značilk na natančnost končne kontrole kakovosti [1].

4 Prenos znanja med različnimi tipi elektromotorjev

Poseben izziv v industriji je faza predserijske proizvodnje, kjer je na voljo zelo malo podatkov. Klasični pristopi strojnega učenja v takšnih razmerah odpovejo, saj potrebujejo veliko učno množico.

Rešitev ponuja prenos znanja (angl. Transfer Learning). Ideja je, da znanje, pridobljeno na velikoserijski proizvodnji enega tipa motorja, prenesemo na sorodne tipe, ki so šele v fazi uvajanja [2]. V praksi se to lahko izvede na dva načina:

- ▶ s prenosom najpomembnejših značilk,
- ▶ s prenosom hiperparametrov in strukture modelov.



Slika 4 : Diagram poteka prenosa znanj [2]

Rezultati so pokazali, da je mogoče z zelo majhnim številom učnih primerov doseči primerljivo ali celo bistveno boljšo natančnost, kot če bi model učili iz nič. To neposredno skrajša čas zagona kontrole kakovosti in zmanjša potrebo po ročnih prilagoditvah. *Slika 4* prikazuje celoten postopek implementacije prenosa znanja, ki se začne z zajemom podatkov in učenjem klasifikatorjev na velikoserijsko proizvedenem tipu elektromotorja ter z oceno njihove uspešnosti, pomembnosti značilk in optimalnih hiperparametrov. Pridobljeno znanje se nato prenese na predserijske tipe elektromotorjev v obliki zmanjšanega nabora vhodnih značilk (prenos značilk) oz. v obliki prenosa hiperparametrov in ocenjevalcev, pri čemer se vzporedno izvede tudi učenje brez prenosa znanja za primerjavo. V zadnjem koraku se uspešnost obeh pristopov ovrednoti in primerja na podlagi točnosti klasifikacije in stroškov napačne razvrstitve, kar omogoča objektivno oceno vpliva prenosa učenja na zanesljivost končne kontrole kakovosti. Celoten potek je predstavljen v [2].

5 Globoko učenje in surovi signali

Čeprav klasično strojno učenje učinkovito zmanjša kompleksnost sistema, še vedno temelji na ročno


definiranih značilkah. Naslednji korak je popolna odprava tega koraka z uporabo globokih nevronskih mrež.

V predstavljenem pristopu [3] se sistem ne uči več na vnaprej izračunanih značilkah, temveč neposredno na surovih vibracijskih in zvočnih signalih. Ti signali se pretvorijo v Mel frekvenčne spektrograme, ki časovno frekvenčno strukturo signala predstavijo v obliki slike.

Za klasifikacijo je uporabljena hibridna arhitektura:

- ▶ konvolucijske nevronske mreže (CNN) za prepoznavanje lokalnih vzorcev v spektrogramih,
- ▶ dvosmerne rekurentne enote (BiGRU) za zajem časovne dinamike signalov.

Takšen model se uči neposredno iz podatkov, brez ročnega modeliranja značilk in pragov. Kljub izrazito neuravnoteženim podatkom (velika večina motorjev je brez napak) so bile dosežene zelo visoke klasifikacijske natančnosti, primerljive ali boljše od klasičnih pristopov. *Slika 5* primerja klasični klasifikacijski model z modelom, ustvarjenim z globokim učenjem [3]. V obeh primerih se postopek začne z zajemom merilnih vibracijskih in zvočnih signa-



Slika 5 : Primerjava klasičnega modela in modela, ki temelji na globokem učenju.

lov, vendar je klasični pristop močno odvisen od ekspertnega znanja. Predlagani pristop uporablja časovno-frekvenčne predstavitve surovih signalov (Mel-frekvenčne spektrograme), na podlagi katerih se nevronska mreža neposredno uči razpoznavnih vzorcev, kar poenostavi razvoj sistema in poveča njegovo prilagodljivost različnim tipom elektromotorjev.

6 Prednosti in odprta vprašanja

Uvedba umetne inteligence v končno kontrolo kakovosti prinaša več pomembnih prednosti:

- ▶ poenostavitev razvoja in vzdrževanja EoL-sistemov,
- ▶ zmanjšanje odvisnosti od strokovnjakov,
- ▶ večja prilagodljivost novim izdelkom,
- ▶ možnost zgodnjega odkrivanja subtilnih napak.

Hkrati pa ostajajo odprta vprašanja, kot so: potreba po označenih podatkih, razločljivost modelov, ki temeljijo na nevronskih mrežah, in njihova integracija v obstoječe industrijske informacijske sisteme.

7 Zaključek

Razvoj EoL-sistemov za elektromotorje jasno kaže, da umetna inteligenca ne nadomešča strokovnjakov,

temveč jim daje nova, močnejša orodja. Prehod od ekspertnih pravil k podatkovno vodenim modelom omogoča bolj robustne, prilagodljive in učinkovite sisteme kontrole kakovosti. Uporabljeni algoritmi strojnega učenja, ansambelski modeli in globoke nevronske mreže pomembno prispevajo k zanesljivejšemu zaznavanju napak in hitrejši prilagoditvi sistemov novim proizvodnim razmeram. V prihodnosti lahko pričakujemo še večji poudarek na nenadzorovanem učenju, prenosu znanja in prognostiki, kjer EoL-sistemi ne bodo več zgolj zadnja kontrolna točka, temveč aktiven vir informacij za optimizacijo celotne proizvodnje.

Viri

- [1] J. Mlinarič, B. Pregelj, P. Boškoski, G. Dolanc and J. Petrovčič, "Optimization of reliability and speed of the end-of-line quality inspection of electric motors using machine learning," *Advances in Production Engineering & Management*, vol. 19, no. 2, pp. 183-196, 2024.
- [2] J. Mlinarič, B. Pregelj, P. Boškoski, G. Dolanc and J. Petrovčič, "A transfer learning approach to machine learning-based end-of-line quality inspection," *Advances in Production Engineering and Management*, vol. 20, no. 2, pp. 277-290, 2025.
- [3] J. Mlinarič, B. Pregelj and G. Dolanc, "End-of-Line Quality Control Based on Mel-Frequency Spectrogram Analysis and Deep Learning," *Machines*, vol. 13, no. 7, 2025.

The Use of Artificial Intelligence for End-of-Line Quality Control of Electric Motors

Abstract:

The paper presents modern approaches to end-of-line (EoL) quality inspection, i.e. the final inspection stage in the manufacturing process of electric motors, based on artificial intelligence. Traditional EoL systems rely on extensive signal processing and expert-defined features and thresholds, which limits their adaptability and increases dependence on specialist knowledge. To address these limitations, several machine learning approaches are discussed, including ensemble-based classification models, transfer learning, and deep neural networks. The application of ensemble models enables automatic feature selection and implicit threshold determination, resulting in a significant reduction of model complexity while maintaining or improving classification accuracy. Transfer learning is shown to be particularly effective in pre-production scenarios, where only limited training data are available, allowing faster commissioning of quality inspection systems and improved fault detection reliability. Furthermore, deep learning methods based on convolutional and recurrent neural networks, trained directly on vibration and acoustic signals represented as Mel-frequency spectrograms, eliminate the need for manual feature engineering and achieve high classification accuracy even in highly imbalanced industrial datasets. The presented results demonstrate that artificial intelligence-based EoL systems can simplify diagnostic procedures, reduce reliance on expert knowledge, improve robustness to product variations, and enhance the overall adaptability and efficiency of industrial quality inspection processes.

Keywords:

end-of-line quality inspection, electric motors, machine learning, artificial intelligence, transfer learning, neural networks, vibration, sound