



توسعه مدل پیش‌بینی کننده زبری سطح با استفاده از شبکه عمیق پیچشی

محمد زنگنه نجفی، محمد شهبازی، سیدعلی نیک‌نام*

دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

* ایمیل نویسنده مسئول: saniknam@iust.ac.ir

اطلاعات مقاله

مقاله پژوهشی

دریافت: ۱ شهریور ۱۴۰۳

پذیرش: ۶ آذر ۱۴۰۳

کلیدواژگان:

ماشین‌کاری

یادگیری عمیق

زبری سطح

نشر آوایی

چکیده

زبری سطحی قطعات ماشین‌کاری شده یکی از پارامترهای مهم برای نشان‌دادن کیفیت سطح است که پارامترهای گسترده‌ای در آن تأثیر می‌گذارد. این گزارش یک چارچوب پیش‌بینی و طبقه‌بندی زبری سطح در قطعات فرزکاری است که با استفاده از تکنیک‌های یادگیری عمیق بر روی داده‌ها، مدلی برای پیش‌بینی و کلاسه‌بندی مقادیر زبری سطح ارائه می‌دهد. در مجموع از داده‌های ۱۶۲ آزمایش برای سه آلیاژ آلومینیوم ۷۰۷۵، ۶۰۶۱ و ۲۰۲۴ استفاده شده است که شامل سرعت برشی، عمق برش، نوع پوشش ابزار، نرخ پیشروی ابزار و خروجی زبری سطح است. در این مقاله، سیگنال‌های نشر آوایی ضبط شده در طول آزمایش‌های فرزکاری به تصاویر دوبعدی تبدیل و به شبکه‌های عصبی پیچشی مانند رزنت ۱۸، شافل‌نت، موبایل‌نت و CNN-LSTM به‌عنوان ورودی داده شده‌اند. چهار روش کدگذاری برای تبدیل سیگنال‌های سری زمانی به عکس‌های دوبعدی استفاده شده است. روش انباشت کانال‌های جایگشت شده بادقت بالای ۹۸٪ در بیشتر مدل‌ها بهترین عملکرد را دارد. همچنین با افزایش تعداد کلاس‌ها به بررسی مقادیر دقت در چهار روش ذکر شده پرداخته شده است. شبکه شافل‌نت و موبایل‌نت با دقت ۹۶-۹۹٪ و هزینه محاسباتی کم، یکی از مدل‌های مناسب برای نظارت بلادرنگ می‌تواند استفاده شود. کارایی روش‌ها در شبکه‌های گفته شده نیز تحت دو سطح نویز ۴۰٪ و ۸۰٪ در دو حالت نویز میانگین صفر و نویز با میانگین غیر صفر سنجیده شد.

Developing surface roughness prediction model using deep convolutional network

Mohammad Zangene Najafi, Mohammad Shahbazi, Seyed Ali Niknam*

School of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

* Corresponding Author's Email: saniknam@iust.ac.ir

Article Information

Original Research Paper

Received: 22 August 2024

Accepted: 26 November 2024

Keywords:

Machining

Deep Learning

Surface Roughness

Acoustic Emission

Abstract

Surface roughness of machined parts is a critical parameter indicating surface quality, influenced by various factors. This report presents a deep learning-based framework for predicting and classifying surface roughness in milled parts. The model was developed using data from 162 experiments on three aluminum alloys: 7075, 6061, and 2024, which included cutting speed, cutting depth, tool coating type, feed rate, and surface roughness output. In this study, acoustic emission signals recorded during milling experiments were converted into two-dimensional images and fed into convolutional neural networks such as ResNet18, ShuffleNet, MobileNet and CNN-LSTM. Four encoding methods were used to convert time series signals into 2D images. The Segmented Stacked Permuted Channels (SSPC) method achieved the best performance with an accuracy above 98% across most models. Also, by increasing the number of classes, the accuracy values of the four mentioned methods have been investigated. ShuffleNet and MobileNet with an accuracy of 96-99% and low computational cost, is identified as suitable for real-time monitoring. The methods' efficiency in the mentioned networks was also evaluated under two noise levels (40% and 80%) in both zero-mean noise and non-zero-mean noise scenarios.

Please cite this article using:

Zangene Najafi M, Shahbazi M, Niknam SA. Developing surface roughness prediction model using deep convolutional network. Iranian Journal of Manufacturing Engineering. 2024 Jan 20;11(11):26-36. doi: 10.22034/ijme.2024.474664.2000 [In Persian]

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

۱- مقدمه

ماشین کاری یک روش تولیدی مهم و پیچیده است که وجود آن در بسیاری از بخش‌های تولیدی ضروری است، زیرا بخش قابل توجهی از قطعات تولید شده به این فرایند وابسته هستند. پیچیدگی این فرایند ناشی از تأثیر تعداد زیادی از متغیرهای ورودی بر نتیجه است که ایجاد روابط ورودی-خروجی را چالش برانگیز می‌کند. انتخاب صحیح متغیرهای ورودی، از جمله پارامترهای برش و ویژگی‌های ابزار ماشین، برای دستیابی به نتایج مطلوب، بهبود بهره‌وری، کیفیت قطعه و زمان تولید حیاتی است. بنابراین، پیش‌بینی نتایج فرایند ماشین کاری برای کنترل و برنامه‌ریزی موثر بسیار مهم است [۱]. دو رویکرد اصلی برای پیش‌بینی نتایج ماشین کاری استفاده می‌شود: رویکرد اول، مبتنی بر مدل^۱ و رویکرد دوم، مبتنی بر داده^۲ است. روش‌های مبتنی بر مدل بر درک قوانین فیزیکی برای ایجاد روابط ورودی-خروجی تکیه دارند، اما به دلیل پیچیدگی و حساسیت فرایند ماشین کاری، این روش‌ها همراه با چالش‌هایی هستند. مدل‌های مبتنی بر داده از داده‌های مرتبط با فرایند استفاده می‌کنند، اما جمع‌آوری داده‌ها نیز می‌تواند پرهزینه و زمان‌بر باشد. برخی روش‌ها از داده‌های ثبت شده در گذشته توسط سنسور برای تصمیم‌گیری استفاده می‌کنند که نیازمند تعداد داده‌های قابل توجهی است [۲، ۳]. یکی از پارامترهای مهم خروجی ماشین کاری، زبری سطح است که یک شاخص مهم برای نشان دادن کیفیت سطوح ماشین کاری شده است. پنج دسته اصلی پارامترهای ماشین کاری که بر زبری سطح تأثیر دارند عبارت‌اند از: ویژگی‌های برش، ویژگی‌های دینامیکی، ویژگی‌های قطعه کار، ویژگی‌های ماشین ابزار و ویژگی‌های ابزار است [۴]. بنابراین، اندازه‌گیری دقیق این شاخص کیفیت سطح، بسیار حیاتی و چالش برانگیز است. روش‌های سنتی از سوزن تماسی که باید با سطح قطعه کار در تماس باشند استفاده می‌کنند و دارای قابلیت اعتماد بالا هستند. با این حال، این روش محدودیت‌هایی از قبیل دسترسی پیچیده به اجزاء و بخش‌ها در محیط‌های صنعتی دارد [۵]. به همین دلیل، در سال‌های اخیر تقاضای زیادی برای استفاده از روش‌های مبتنی بر داده برای پیش‌بینی مقادیر زبری سطح در قطعات ماشین کاری وجود داشته است.

در روش مبتنی بر مدل، مقدار زبری سطح از طریق ایجاد یک مدل آماری یا رگرسیون، طبق سطح پاسخ به دست می‌آید. دو عامل کلیدی برای عملکرد موثر روش‌های مبتنی بر داده، انتخاب مدل پیش‌بینی مناسب و در نظر گرفتن ویژگی‌های استخراج شده به‌عنوان ورودی‌ها هستند [۴]. روش‌های یادگیری ماشین مختلفی وجود دارند که می‌توانند مقادیر زبری سطح را پیش‌بینی و تخمین بزنند، از جمله ماشین بردار پشتیبان^۳ [۶-۸] (SVM)، شبکه‌های عصبی مصنوعی^۴ [۹-۱۱] (ANN). همچنین با استفاده از الگوریتم‌های هوش مصنوعی و الگوریتم بهینه‌سازی به پیش‌بینی مقادیر زبری سطح در آلیاژهای آلومینیوم پرداخته‌اند [۱۲، ۱۳].

توجه به توسعه و استفاده از یادگیری عمیق به دلیل توانایی آن در غلبه بر چالش‌های استخراج ویژگی، خصوصیات تعمیم ویژگی و پردازش مجموعه داده‌های صنعتی بزرگ جلب شده است. تمرکز بر روی ساختار شبکه‌ها با لایه‌های چندگانه از واحدهای پردازش غیرخطی است. شبکه‌های معروف در این حوزه شامل شبکه‌های عصبی پیچشی^۵ (CNNs) [۴، ۱۴، ۱۵] و شبکه‌های عصبی بازگشتی^۶ (RNNs) [۱۶] هستند. شبکه‌های عصبی پیچشی برای وظایفی با داده‌های شبکه‌ای، مانند تصاویر هستند و از تشخیص ویژگی‌های سلسله مراتبی خود استفاده می‌کنند. شبکه‌های عصبی بازگشتی نیز برای پردازش داده‌های توالی مؤثر هستند.

استفاده از فناوری یادگیری عمیق در پیش‌بینی فرایندهای ماشین کاری پتانسیل بزرگی برای پیشرفت دارد. این فناوری به درک ارتباط بین فرایند و ویژگی‌ها کمک می‌کند که منجر به دقت بیشتر در پیش‌بینی می‌شود. با استفاده از یادگیری عمیق، می‌توان به مدل‌سازی حجم زیادی از داده‌های صنعتی، بدون استخراج دستی ویژگی‌ها پرداخت که منجر به ارزیابی آسان‌تر دقت مدل‌سازی می‌شود. مدل‌های پیچیده با استفاده از یادگیری عمیق قابل ایجاد هستند و با در نظر گرفتن بیشتر داده‌ها، تأثیر قابل توجهی بر خروجی فرایند می‌توان داشت. این رویکرد امکان ارتباط بین پارامترهای فرایند و خروجی فرایند را فراهم می‌کند. اعمال این روش می‌تواند کنترل کیفی قطعات ماشین کاری و بهینه‌سازی فرایند را بهبود بخشد.

¹ Model-based Design

² Data Driven

³ Support Vector Machines

⁴ Artificial Neural Networks

⁵ Convolutional Neural Networks

⁶ Recurrent Neural Networks

۲- مواد و روش‌ها

در این گزارش آزمایش‌های تجربی بر روی سه آلیاژ آلومینیوم با فرایند فرزکاری و استراتژی فرزکاری شیار^۱ با فرز سه دندانه به قطر ۱۹،۰۵ میلیمتر و زاویه مارپیچ ۳۰ درجه بر روی بلوک‌هایی به ابعاد ۲/۱×۵/۳×۵/۳ سانتی‌متر انجام شده است. برای هر کدام از سه جنس آلومینیوم تعداد ۵۴ آزمایش در نظر گرفته شده است. ورودی‌های فرایند به تفصیل در جدول ۱ آورده شده است.

جدول ۱ پارامترهای ورودی ماشین‌کاری

علامت	پارامتر ورودی	سطح		
		۱	۲	۳
V_c	سرعت برش (m/min)	۳۰۰	۷۵۰	۱۲۰۰
f_z	نرخ پیشروی (mm/tooth)	۰،۰۱	۰،۰۵۵	۰،۱
a_p	عمق برش (mm)	۱	۲	-
Tool	ابزار برشی:	TiCN	TiAlN	TiCN+Al ₂ O ₃ +TiN
	پوشش	۰.۵	۰.۸۳	۰.۵
	شعاع نوک ابزار			

تست‌های فرزکاری شیار بر روی یک ماشین‌ابزار کنترل عددی رایانه‌ای^۲ (CNC) سه محور (HURON - K2X10)، قدرت ۵۰ کیلووات، سرعت ۲۸۰۰۰ دور در دقیقه، گشتاور ۵۰ نیوتن متر) انجام شده است. دو سنسور میکروفون برای تشخیص سیگنال‌های نشر آوایی قرار گرفتند. جمع آوری داده‌ها با استفاده از این حسگرهای AE با فرکانس نمونه برداری ۶۰ کیلوهرتز انجام شده است. اقدامات کنترلی دقیق در طول آزمایش‌های اولیه برای اطمینان از ثبات در فرایند برش و نظارت بر ارتعاشات ماشین و ابزار و رفتار دینامیکی اجرا شده است.

علاوه بر این، یک حسگر نشر آوایی در فاصله ۲ متری از ناحیه برش قرار گرفته است تا نویز پس زمینه را ارزیابی کند. نسبت قابل توجه سیگنال به نویز^۳ (SNR) مشاهده شده بین سنسورهای اول و دوم، تأثیر محدود نویز پس‌زمینه را بر دقت سیگنال ثبت شده توسط حسگر اول، که در نزدیکی ناحیه تشکیل تراشه قرار دارد، تأیید می‌کند.

پس از اتمام عملیات، پارامتر زبری سطح Ra، با استفاده از پروفیل متر سطح Mitutoyo SJ 400 اندازه‌گیری شده است. در این گزارش، مقادیر زبری سطح با استفاده از جدول ۲ به پنج دسته تقسیم بندی شده‌اند.

جدول ۲ کلاس‌بندی بازه اعداد زبری سطح


شماره کلاس	بازه اعداد زبری سطح
۱	≤ 0.2
۲	0.2 - 0.3
۳	0.301 - 0.4
۴	0.401 - 0.6
۵	$0.6 \leq$

شکل ۱ نشان دهنده قطعات آلومینیومی و میکروفون‌های نصب شده برای ضبط داده‌های نشر آوایی و پردازش داده را نشان می‌دهد.

¹ Slot Milling

² Computer Numerical Control

³ Signal-to-Noise Ratio



شکل ۱ ستاپ پردازشی ماشین کاری قطعات آلومینیومی و داده‌برداری

۲-۱-۲- رویکرد مدل‌سازی

تبدیل سیگنال‌های سری زمانی به تصاویر دوبعدی با استفاده از الگوریتم‌های متنوع برای آموزش شبکه‌های پیچشی مفید است. این تغییر ساختار داده‌های سری زمانی امکان یادگیری مؤثر وابستگی‌های زمانی را فراهم می‌کند. انتخاب روش مناسب برای تبدیل سیگنال‌های زمانی به تصاویر دوبعدی می‌تواند بر عملکرد شبکه تأثیر بگذارد. استفاده از تکنیک‌های پردازش تصویر برای پیش‌پردازش داده‌ها نیز راهی دیگر برای افزایش کارایی شبکه است.

۲-۱-۱-۲- انباشت کانال‌های جایگشت شده^۱ (SSPC)

در این روش با دریافت دو کانال سیگنال نشر آوایی، با اعمال ریاضی و انتخاب یک پنجره برای برداشت داده در طول سری زمانی بر طبق فرمول زیر مورد استفاده قرار می‌گیرد:

$$V(t) = [A(t), B(t)] \quad (1)$$

$$M = \text{reshape}(V(t), [T, F]) \quad (2)$$

که در آن $V(t)$ نشان دهنده بردار ترکیبی از هر دو کانال نشر آوایی است. سپس با یک عملیات ساده با یک تغییر شکل به یک تصویر دو بعدی تبدیل شده اند که $[T, F]$ سایز تصویر مورد نیاز است. مزیت این روش عملیات ساده برای ایجاد تصاویر دو بعدی از یک سیگنال تک بعدی است در حالی که باعث می‌شود دیگر محور افقی بیانگر زمان نباشد.

۲-۱-۲- انباشت کانال‌های نمونه برداری شده^۲ (SSSC/SSSC*)

در این روش، کانال دوم به‌عنوان سیگنال نویز محیطی در نظر گرفته می‌شود. با کم کردن کانال دوم از کانال اول، یک کانال سوم ایجاد می‌شود که نشان‌دهنده سیگنال نشر آوایی تا حدی بدون نویز است. انتخاب پنجره‌های زمانی برای بخش اعمال شده روی سیگنال

¹ Segmented Stacked Permuted Channels (SSPC)

² Segmented Sampled Stacked Channels (SSSC/SSSC*)


تأثیر قابل توجهی بر اندازه تصویر دارد. در این رویکرد از دو روش برای کاهش اندازه تصاویر تولید شده استفاده می‌شود. روش اول از نمونه‌گیری خطی استفاده می‌کند. این شامل انتخاب یک نقطه نماینده از چندین نقطه بین اندازه اولیه و نهایی قطعه است. این تضمین می‌کند که طول بردار به طول موردنظر برسد. روش دوم از نمونه‌گیری میانگین‌گیری استفاده می‌کند. در اینجا یک میانگین برای هر امتیاز محاسبه می‌شود که به عنوان یک نمره نماینده عمل می‌کند. این باعث کاهش طول بردارها از هر سه کانال می‌شود.

۲-۱-۳- Recurrence Plot (RP)

سری‌های زمانی رفتار تکرارشونده متمایزی از جمله دوره‌های تناوب و چرخه‌های نامنظم را نشان می‌دهند که اغلب در سیستم‌های غیرخطی پویا یا فرایندهای تصادفی مشاهده می‌شوند [۱۷]. Recurrence Plot به عنوان یک ابزار تجسم برای کاوش مسیر فضای فاز m بعدی عمل می‌کند و نمایشی دوبعدی از فاز را ارائه می‌دهد. با نشان دادن نقاطی که در آن مسیرها به حالت‌های قبلی باز می‌گردند، RP یک ابزار پرکاربرد برای تجزیه و تحلیل رفتارهای تکرار شونده در سری‌های زمانی تولید شده توسط سیستم‌های دینامیکی است. می‌توان آن را به صورت زیر فرموله کرد:

$$R_{i,j} = H(\epsilon - \|\vec{s}_i - \vec{s}_j\|), \quad \vec{s}(\cdot) \in R^m, i, j = 1, \dots, N \quad (3)$$


که در آن $\|\cdot\|$ عملیات نرمال سازی^۱، ϵ حد آستانه^۲ و H تابع هوی ساید^۳ است. N تعداد حالت‌ها و m فضای فاز است. در شکل ۲ نمونه تصاویر ساخته شده به سه روش گفته شده نمایش داده شده است.



شکل ۲ نمونه تصاویر ساخته شده از سیگنال نشر آوایی. (الف) روش اول، (ب) روش دوم، (ج) روش سوم

۲-۲- معماری شبکه و معیارهای ارزیابی

در این گزارش از پنجره زمانی ۲۰۴۸ نقطه زمانی در هر دو کانال استفاده شده است. همپوشانی مورد نظر ۷۵ درصد است. هر کدام از این پنجره‌ها شامل دو کانال اصلی در هر سه روش می‌باشد. علاوه بر این، عملیاتی مانند نرمال سازی داده‌های هر پنجره و سایر عملیات پردازشی روی این پنجره‌ها انجام شده است. این در شکل ۳ نشان داده شده است. در نهایت عکس‌ها با اندازه ۶۴*۶۴ ایجاد می‌شوند که به عنوان ورودی شبکه پیچشی استفاده می‌شوند.



شکل ۳ ساختار ایجاد تصاویر دوبعدی از سیگنال‌های سری زمانی

¹ Operation Norm

² Threshold

³ Heaviside

در این مطالعه از چهار شبکه عصبی عمیق استفاده شده است. سه شبکه اول رزنت ۱۸، شافل نت و موبایل نت، معماری‌هایی مبتنی بر شبکه‌های پیچشی هستند و مورد استفاده قرار گرفتند. چهارمین مدل، مدل مبتنی بر یک شبکه حافظه کوتاه مدت بلند مدت^۱ (LSTM)، یکی از کارآمدترین‌ها برای تجزیه و تحلیل داده‌های متوالی و سری‌های زمانی است. استفاده از یادگیری انتقالی امکان توسعه سریع مدل‌هایی با کارایی و اثربخشی بالا را فراهم کرده است. مدل‌های از پیش آموزش دیده برای استخراج ویژگی‌ها از تصاویر ورودی استفاده شد.

برای کارهای طبقه‌بندی، صحت یا درستی^۲ یکی از معیارهای اندازه‌گیری شبکه‌های عصبی است. البته این معیار نمی‌تواند همیشه مثلاً کارایی بالای شبکه را نشان دهد. اگر داده‌ها نامتعادل باشند، اقداماتی غیر از صحت باید نظارت و گزارش شود؛ بنابراین علاوه بر صحت، معیارهای دیگری نیز برای ارزیابی شبکه‌ها مورد استفاده قرار می‌گیرد؛ بنابراین، اتخاذ معیارهای ارزیابی صحیح در وظایف یادگیری عمیق برای بهینه‌سازی عملکرد طبقه‌بندی کننده‌ها بسیار مهم است. دقت^۳، فراخوانی^۴ و امتیاز اف وان^۵ نیز از دیگر معیارهای ارزیابی کارایی شبکه هستند که در ادامه از آنها استفاده شده است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۴)$$

$$Precision = \frac{TP}{TP + FP} \quad (۵)$$

$$Recall = \frac{TP}{TP + FN} \quad (۶)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (۷)$$

که TP مثبت درست^۶، TN منفی درست^۷، FP مثبت غلط^۸ و FN منفی غلط^۹ است. شکل ۳ شماتیکی از کارهای پردازشی بر روی سیگنال‌ها برای به دست آوردن تصاویر است.

۳- نتایج و بحث

این بخش دقت طبقه‌بندی مدل را هنگام تولید تصاویر دوبعدی از سیگنال‌های سری زمانی با استفاده از معماری‌های مختلف شبکه عصبی بررسی می‌کند. عملکرد شبکه با اضافه کردن نویز در سطوح و حالت‌های مختلف ارزیابی می‌شود تا مشخص شود که چگونه بر دقت تأثیر می‌گذارد.

هنگام تجزیه و تحلیل ماتریس همبستگی بین پارامترهای فرایند و طبقات زبری سطح بر اساس شکل ۴، بدیهی است که بین پارامترهای بسیار مهم فرایند مانند سرعت برش، عمق برش، نرخ تغذیه و کلاس زبری سطح حاصل این مشاهدات ماهیت پیچیده و غیرخطی دینامیک اساسی حاکم بر این فرایندهای تولید را برجسته می‌کند. فقدان یک همبستگی واضح نشان می‌دهد که تشخیص جزئیات دقیق در تعامل بین پارامترهای فرایند و زبری سطح از طریق روش‌های تحلیل سنتی آسان نیست. بنابراین، استفاده از شبکه‌های عصبی عمیق برای کشف روابط و الگوهای پیچیده در داده‌ها ضروری است. توانایی ذاتی شبکه‌های عمیق برای گرفتن وابستگی‌های پیچیده و نمایش‌های سلسله مراتبی، آنها را به ابزارهای ارزشمندی برای تشخیص روابط ظریف تبدیل می‌کند که ممکن است از رویکردهای تحلیلی مرسوم دوری کنند. این کشف بر اهمیت استفاده از روش‌های پیشرفته برای کشف روابط پنهان در داده‌های پیچیده تأکید دارد.

برای آموزش شبکه عصبی پیچشی از تصاویر ورودی با اندازه ۶۴×۶۴ پیکسل و تک کانال با اندازه دسته ۱۶ استفاده می‌شود. توزیع طبقه‌بندی بر اساس جدول ۵ بود. برای فرایند آموزش، ۸۰٪ از کل مجموعه داده برای داده‌های آموزشی استفاده شد. پس از آن، ۲۰٪

¹ Long Short-Term Memory

² Accuracy

³ Precision

⁴ Recall

⁵ F1-Score


⁶ True Positive

⁷ True Negative

⁸ False Positive

⁹ False Negative

باقیمانده به دو بخش، ۵۰٪ برای داده‌های اعتبارسنجی و ۵۰٪ باقی مانده برای داده‌های تست تقسیم شد. یک بهینه‌ساز گرادیان تصادفی^۱ (SGD) با نرخ یادگیری^۲ ۰,۰۰۱ و تکانه ۰,۹ برای آموزش شبکه پیچشی استفاده می‌شود. این پارامترها برای بهینه‌سازی همگرایی شبکه در طول تکرارهای آموزشی انتخاب شدند.



شکل ۴ ماتریس اختلاط بین پارامترهای برش و کلاس‌های زبری سطح

جدول ۳ دقت آموزش برای چهار روش تولید تصویر را در چهار معماری شبکه مختلف نشان می‌دهد. نتایج نشان می‌دهد که در ۳ شبکه اول که معماری‌های مختلف شبکه‌های پیچشی هستند، روش اول و سوم بالاترین دقت را دارند. در شبکه چهارم GNN-LSTM به دلیل عدم نمایش زمان در محور افقی تصاویر، دقت کاهش یافته است.

جدول ۳ مقادیر صحت (درستی، به درصد) در معماری شبکه‌ها و روش‌های مختلف

روش‌های تبدیل سیگنال به تصویر				مدل شبکه	
RP	SSSC*	SSSC	SSPC		
99.44	99.45	99.48	99.52	داده آموزشی	رزنت ۱۸
89.45	95.7	98.54	99.46	داده اعتبارسنجی	
89.49	95.84	98.6	99.37	داده تست	
96.82	97.53	99.19	99.22	داده آموزشی	شافلنت
80.8	91.42	96.75	98.26	داده اعتبارسنجی	
81.3	91.36	96.73	98.51	داده تست	
98.23	99.51	99.50	99.56	داده آموزشی	موبایلنت
92.36	99.47	99.45	99.3	داده اعتبارسنجی	
92.45	99.28	99.52	99.36	داده تست	
99.34	99.42	99.52	99.19	داده آموزشی	CNN-LSTM
89.47	95.05	98.62	94.83	داده اعتبارسنجی	
89.39	95.76	98.68	94.64	داده تست	

¹ Stochastic Gradient Descent

² Learning Rate

در جدول ۴، مقایسه‌ای بین میانگین دقت، یادآوری، و امتیاز F1 برای چهار روش رمزگذاری تصویر نشان داده شده است. روش اول با دقت بالای ۹۸٪ برای اکثر مدل‌ها بهترین عملکرد را داشته است، با این حال معماری CNN-LSTM به دلیل وابستگی زمانی دقت خود را به ۹۴٫۶۴٪ کاهش داده است. روش ۲ (SSSC) نیز عملکرد خوبی داشته و با دقت ۹۶٫۷۳٪، به‌ویژه در مدل شافل‌نت روش ۳ (SSSC*) عملکرد مشابهی نسبت به روش ۲ داشت، اما با دقت کمتر، به‌ویژه برای مدل‌های رزنت ۱۸ و شافل‌نت. روش ۴ (RP) نتایج نهایی را با دقت کمتر از ۸۹٫۴۹٪ برای همه مدل‌ها نشان داد. به طور خلاصه، استفاده از روش‌هایی که داده‌های اصلی را حفظ می‌کنند (روش‌های ۱ و ۲)، منجر به دقت بالاتری نسبت به روش‌هایی می‌شود که داده‌ها را تغییر می‌دهند یا نمونه‌برداری پایین می‌کنند (روش‌های ۳ و ۴).

جدول ۴ مقادیر دقت داده‌های تست و سایر معیارهای ارزیابی برای شبکه‌ها و روش‌های مختلف

روش‌های تبدیل سیگنال به تصویر				مدل شبکه	
RP	SSSC*	SSSC	SSPC		
89.49	95.84	98.5	99.51	Accuracy	رزنت ۱۸
89.59	95.87	95.8	99.52	Precision	
89.49	95.84	95.84	99.51	Recall	
89.53	95.85	95.85	99.51	F1 Score	
81.38	91.36	96.73	98.51	Accuracy	شافل‌نت
81.29	90.65	96.35	98.43	Precision	
81.38	90.42	95.25	98.51	Recall	
81.25	90.39	96.21	98.36	F1 Score	
92.45	99.28	99.52	99.36	Accuracy	موبایل‌نت
92.18	99.28	99.53	99.36	Precision	
92.00	99.2	99.52	99.3	Recall	
92.32	99.25	99.51	99.31	F1 Score	
89.39	95.76	98.68	94.64	Accuracy	CNN-LSTM
89.56	95.21	98.68	94.71	Precision	
89.39	95.7	98.68	94.64	Recall	
89.44	95.65	98.68	94.66	F1 Score	

یکی از روش‌ها برای به‌دست‌آوردن بازه دقیق‌تر اعداد زبری سطحی، بالابردن تعداد کلاس‌ها است. بدین ترتیب که با استفاده از مقادیر گسسته در بازه‌های کوچک بتوان تقریب مناسبی از اعداد زبری سطح در قطعات ارائه داد. در این گزارش علاوه بر تعداد کلاس‌های گفته شده در جدول ۲، تعداد کلاس‌ها به تعداد ۱۰ کلاس افزایش داده و سپس با استفاده از ۴ روش ساخت عکس، ادامه کار انجام می‌شود. بازه‌ی کلاس‌ها به این صورت است که هر بازه بزرگتر را به دو زیر بازه ریزتر تقسیم کرده و تعداد کلاس‌ها افزایش پیدا می‌کند. مقادیر جدید کلاس‌های زبری سطحی در جدول ۵ آمده است.

جدول ۵ کلاسه‌بندی بازه اعداد زبری سطح

شماره کلاس	بازه اعداد زبری سطح
۱	0.075 - 0.1
۲	0.1 - 0.15
۳	0.15 - 0.2
۴	0.2 - 0.3
۵	0.3 - 0.4
۶	0.4 - 0.6
۷	0.6 - 0.8
۸	0.8 - 1.2
۹	1.2 - 1.6
۱۰	1.6 - 2.4

همچنین در جدول ۶ نیز اعداد دقت شبکه شافل‌نت برای ۴ روش ساخت تصاویر آورده شده است.

جدول ۶ مقادیر صحت (درستی) در روش‌های مختلف برای تعداد ۱۰ کلاس

روش‌های تبدیل سیگنال به تصویر				مدل شبکه
RP	SSSC*	SSSC	SSPC	
90.87	96.61	97.69	99.54	داده آموزشی
83.65	94.69	96.53	99.48	داده اعتبارسنجی
83.49	94.74	96.69	99.42	داده تست

همانطور که از جدول ۶ مشخص است با افزایش تعداد کلاس‌ها به عدد ۱۰ کلاس، در روش SSPC افت زیادی ندارد در حالی که در روش‌های داده برداری (میانگین گیری و خطی) افت دقت نسبت به حالتی که تعداد کلاس‌ها عدد ۵ است محسوس است. در صنعت، وجود سیگنال‌های نویز ناشی از عواملی مانند تداخل الکترومغناطیسی یا استفاده از سنسورهای ضعیف می‌تواند به طور قابل توجهی بر دقت سیستم‌های پایش تأثیر بگذارد. این سیگنال‌های پر سروصدا در تمایز بین رفتار عادی و غیرعادی چالش ایجاد می‌کنند. آزمایش‌هایی تحت سطوح مختلف تداخل، شبیه‌سازی شرایط با نویز سیگنال مختلف، برای ارزیابی استحکام شبکه‌ها در چنین محیط‌هایی انجام شده است. مقادیر مختلف نویز گاوسی به سیگنال‌های ورودی قبل از تبدیل آنها به تصاویر اعمال شده است. جدول ۵ نتایج ارزیابی را با تمرکز بر دقت مدل‌ها در سطوح مختلف نویز نشان می‌دهد که بر اساس روش کدگذاری طبقه بندی شده‌اند.

جدول ۷ تأثیر سطوح مختلف نویز بر کارایی شبکه شافل‌نت در روش‌های مختلف ساخت تصاویر

روش‌های تبدیل سیگنال به تصویر				سطح نویز	نویز با میانگین غیر صفر
RP	SSSC*	SSSC	SSPC		
96.75	95.46	99.128	98.24	سطح اول (۴۰ درصد)	
75.43	53.79	94.8	92.5		
75.53	53	94.64	92.29		
93.16	95.36	98.46	95.47	سطح اول (۸۰ درصد)	
71.22	43.67	91.76	80.21		
70.73	43.91	91.48	79.97		
97.54	97.23	99.34	99.47	سطح اول (۴۰ درصد)	
82.34	77.39	96.12	96.19		
81.87	77.05	96.31	96.07		
97.65	97.54	99.47	98.14	سطح اول (۸۰ درصد)	نویز با میانگین صفر
74.22	65.76	95.59	91.09		
74.69	65.64	95.71	90.29		

در جدول ۷ تأثیر نویز گاوسی^۱ بر دقت مدل در دو سطح با انحراف استاندارد ۰,۴ (سطح ۱) و ۰,۸ (سطح ۲) نسبت به محدوده سیگنال ورودی بر روی شبکه شافل‌نت آزمایش شد. نویز با توزیع میانگین صفر و میانگین غیر صفر معرفی شد. در تمام سطوح و توزیع‌های نویز، روش ۱ (رمزگذاری SSPC) قوی‌ترین روش بود که دقت آموزش را بالای ۹۵ درصد و دقت تست را بالای ۹۰ درصد حتی در بالاترین سطح نویز حفظ کرد. روش ۲ (رمزگذاری SSSC) همچنین انعطاف‌پذیری قوی در برابر نویز نشان داد، اگرچه کمی بدتر از روش ۱ بود. روش‌های ۳ و ۴ عملکرد قابل ملاحظه‌ای در زیر نویز کاهش دادند، با کاهش دقت بر روی داده‌های تست به حدود ۷۵-۵۰٪. اختلاف در عملکرد بین روش‌های ۱ و ۲ و روش‌های ۳ و ۴ در نویز سطح ۲ بیشتر شد، که نشان‌دهنده عدم استحکام نسبی آنها تا شرایط نویز متوسط است. علاوه بر این، نویز با میانگین غیر صفر منجر به کاهش بیشتر در دقت نسبت به نویز با میانگین صفر در تمام روش‌ها و سطوح نویز شد. به طور خلاصه، روش‌های ۱ و ۲ بیشترین توانایی را در تشخیص رفتار غیرعادی در محیط‌های پر سر و صدا داشتند.

¹ Gaussian Noise

۴- نتیجه گیری

این مقاله پتانسیل استفاده از روش‌های مختلف رمزگذاری سیگنال‌های سری زمانی را برای پیش‌بینی و طبقه‌بندی مقادیر زبری سطح با استفاده از شبکه‌های پیچشی عمیق بررسی می‌کند. این چارچوب شامل ایجاد تصاویر دوبعدی با استفاده از چهار روش مختلف است که سیگنال‌های سری زمانی ثبت شده در طول فرایند ماشین‌کاری را به‌عکس تبدیل می‌کند. شبکه‌های پیچشی عمیق مانند رزنت، شافل‌نت، موبایل‌نت و CNN-LSTM برای بررسی صحت و کارایی هر شبکه و ارزیابی مقادیر هزینه محاسباتی استفاده شده‌اند. برای تعیین دقیق‌تر کارایی شبکه‌ها، سطوح مختلف نویز به داده‌های ورودی اضافه شد تا مقادیر دقت شبکه‌ها پس از اضافه شدن نویز بهبود یابد.

- روش SSPC در مقایسه با سایر روش‌های موجود نیاز به پیش‌پردازش کمتری دارد و برای ایجاد تصاویر راحت‌تر است. در این روش برخلاف روش‌های دیگر از تمامی داده‌ها استفاده می‌شود و از بین نمی‌رود. نتایج نشان می‌دهد که این روش به جز شبکه CNN-LSTM که ماهیت زمانی و بازگشتی دارد، بالاترین دقت را دارد. با این حال، از آنجایی که این عکس هیچ ماهیت زمانی را ذکر نمی‌کند، روش SSSC دقیق‌ترین روش است.
- نتایج نشان می‌دهند که از بین دو روش نمونه‌گیری خطی SSSC و میانگین‌گیری SSSC*، روش میانگین‌گیری نتایج بهتری را نسبت به نمونه‌برداری خطی ارائه می‌کند. اگرچه تفاوت بین روش SSPC و روش میانگین‌گیری اندک است، اما هنوز هم می‌توان از روش دوم برای کاهش هزینه محاسباتی سیستم استفاده کرد.
- می‌توان به جای فرایند رگرسیون، تعداد کلاس‌ها را زیاد کرد که بازه‌های انتخابی کوچک شوند و بازه پیش‌بینی شده به عدد پیش‌بینی شده نزدیک شود.
- با توجه به هزینه محاسباتی پایین شبکه شافل‌نت و موبایل‌نت، بهتر است از شبکه موبایل‌نت برای پیش‌بینی بلادرنگ و لزوماً آنلاین استفاده شود.
- روش SSPC به پیش‌پردازش کمتری نسبت به روش‌های دیگر مانند SSSC نیاز دارد، به این معنی که ممکن است زمانی که نویز به مقادیر داده اصلی اضافه می‌شود، عملکرد کمتری داشته‌باشد. به عنوان مثال، هنگامی که نویز با میانگین غیر صفر با سطح یک وجود دارد، افت دقت در داده‌های تست برای روش SSSC تنها حدود دو درصد است که منجر به دقت ۹۴٫۶۴ درصد می‌شود، در حالی که روش SSPC حدود یک درصد افت را تجربه می‌کند. منجر به دقت ۹۲٫۲۹ درصد می‌شود.

References

- [1] Serin G, Sener B, Ozbayoglu AM, Unver HO. Review of tool condition monitoring in machining and opportunities for deep learning. *The International Journal of Advanced Manufacturing Technology*. 2020 Jul;109(3):953-74. doi: 10.1007/s00170-020-05449-w
- [2] Bai L, Yang Q, Cheng X, Ding Y, Xu J. A hybrid physics-data-driven surface roughness prediction model for ultra-precision machining. *Science China Technological Sciences*. 2023 May;66(5):1289-303. doi: 10.1007/s11431-022-2358-4
- [3] Guo M, Wei S, Han C, Xia W, Luo C, Lin Z. Prediction of surface roughness using deep learning and data augmentation. *Journal of Intelligent Manufacturing and Special Equipment*. 2024 Jan 29. doi: 10.1108/JIMSE-10-2023-0010
- [4] Lin WJ, Lo SH, Young HT, Hung CL. Evaluation of deep learning neural networks for surface roughness prediction using vibration signal analysis. *Applied Sciences*. 2019 Apr 8;9(7):1462. doi: 10.3390/app9071462
- [5] Feng P, Borghesani P, Smith WA, Peng Z. Model-based surface roughness estimation using acoustic emission signals. *Tribology International*. 2020 Apr 1;144:106101. doi: 10.1016/j.triboint.2019.106101
- [6] Abu-Mahfouz I, El Ariss O, Esfakur Rahman AH, Banerjee A. Surface roughness prediction as a classification problem using support vector machine. *The International Journal of Advanced Manufacturing Technology*. 2017 Sep;92:803-15. doi: 10.1007/s00170-017-0165-9
- [7] Yeganfar A, Niknam SA, Asadi R. The use of support vector machine, neural network, and regression analysis to predict and optimize surface roughness and cutting forces in milling. *The International Journal of Advanced Manufacturing Technology*. 2019 Nov;105:951-65. doi: 10.1007/s00170-019-04227-7
- [8] Dubey V, Sharma AK, Pimenov DY. Prediction of surface roughness using machine learning approach in MQL turning of AISI 304 steel by varying nanoparticle size in the cutting fluid. *Lubricants*. 2022 May 2;10(5):81. doi: 10.3390/lubricants10050081

- [9] Kant G, Sangwan KS. Predictive modelling and optimization of machining parameters to minimize surface roughness using artificial neural network coupled with genetic algorithm. *Procedia Cirp*. 2015 Jan 1;31:453-8. doi: [10.1016/j.procir.2015.03.043](https://doi.org/10.1016/j.procir.2015.03.043)
- [10] Khorasani A, Yazdi MR. Development of a dynamic surface roughness monitoring system based on artificial neural networks (ANN) in milling operation. *The International Journal of Advanced Manufacturing Technology*. 2017 Oct;93:141-51. doi: [10.1007/s00170-015-7922-4](https://doi.org/10.1007/s00170-015-7922-4)
- [11] Gupta AK, Guntuku SC, Desu RK, Balu A. Optimisation of turning parameters by integrating genetic algorithm with support vector regression and artificial neural networks. *The International Journal of Advanced Manufacturing Technology*. 2015 Mar;77:331-9. doi: [10.1007/s00170-014-6282-9](https://doi.org/10.1007/s00170-014-6282-9)
- [12] Imani L, Rahmani Hanzaki A, Hamzeloo SR, Davoodi B. Modeling and optimization of cutting force and surface roughness in the milling process of Inconel 738 by Neural Network and Genetic Algorithm. *Iranian Journal of Manufacturing Engineering*. 2019 Oct 23;6(5):25-38. [In Persian]
- [13] Siahvashi A, Shahbazi M, Niknam SA. The use of a neuro-fuzzy network coupled with meta-heuristic learning methods to predict surface roughness in the machining of aluminum alloys. *Iranian Journal of Manufacturing Engineering*. 2024;10(11):49-60. doi: [10.22034/ijme.2024.412021.1816](https://doi.org/10.22034/ijme.2024.412021.1816) [In Persian]
- [14] Huang PM, Lee CH. Estimation of tool wear and surface roughness development using deep learning and sensors fusion. *Sensors*. 2021 Aug 7;21(16):5338. doi: [10.3390/s21165338](https://doi.org/10.3390/s21165338)
- [15] Pan Y, Kang R, Dong Z, Du W, Yin S, Bao Y. On-line prediction of ultrasonic elliptical vibration cutting surface roughness of tungsten heavy alloy based on deep learning. *Journal of Intelligent Manufacturing*. 2022 Mar 1:1-1. doi: [10.1007/s10845-020-01669-9](https://doi.org/10.1007/s10845-020-01669-9)
- [16] Guo W, Wu C, Ding Z, Zhou Q. Prediction of surface roughness based on a hybrid feature selection method and long short-term memory network in grinding. *The International Journal of Advanced Manufacturing Technology*. 2021 Feb;112:2853-71. doi: [10.1007/s00170-020-06523-z](https://doi.org/10.1007/s00170-020-06523-z)
- [17] Kirichenko L, Zinchenko P, Radivilova T. Classification of time realizations using machine learning recognition of recurrence plots. In *International Scientific Conference "Intellectual Systems of Decision Making and Problem of Computational Intelligence"* 2020 May 25 (pp. 687-696). Cham: Springer International Publishing. doi: [10.1007/978-3-030-54215-3_44](https://doi.org/10.1007/978-3-030-54215-3_44)