

Л.М. Девін, М.П. Беженар, доктори технічних наук,
С.В. Ричев¹, Н.Є.Тіщенко², О.В. Грязев, В.М. Нечипоренко¹

¹Інститут надтвердих матеріалів ім. В. М. Бакуля НАН України, вул. Автозаводська 2, 04074 м. Київ, e-mail: ldevin350@gmail.com

²Національний технічний університет України “Київський політехнічний інститут імені Ігоря Сікорського”, пр. Берестейський 37, 03056, м. Київ, Україна

ВИКОРИСТАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ОЦІНКИ ПРАЦЕЗДАТНОСТІ РІЗАЛЬНИХ ІНСТРУМЕНТІВ ІЗ ПКНБ

Представлено методику та результати дослідження складових сил різання та вібрацій під час чистового точіння загартованої сталі ШХ15 (HRC 50–60). Для встановлення зв'язку складових сил різання з вібраціями використовували підхід, який базується на побудові моделей, що враховують різноманітні невизначеності. Для цього застосували розроблену на мові Python та Google Colab штучну нейронну мережу (ШНМ). Досліджували різці з різальними вставками з 5-ти видів полікристалічних матеріалів на основі кубічного нітриду бору. Розроблена нейронна мережа мала складну архітектуру, яка включала шість прихованих шарів. Кількість нейронів у цих шарах варіювалася від 32 до 256. Середня відносна похибка при використанні ШНМ була не більше 12%, що дозволяє використовувати ШНМ в дослідженнях працездатності різальних інструментів з ПКНБ. Результати дослідження відкривають нові перспективи подальшого розвитку адаптивних систем керування верстатами на основі контролю вібрацій в процесі механічної обробки.

Ключові слова: діагностика стану інструменту, штучні нейронні мережі, полікристали надтвердих матеріалів, кубічний нітрид бору, вібрації, складові сили різання, ймовірність руйнування.

Актуальність проблеми та стан питання

Для діагностики стану різця в процесі обробки необхідно знати напруження в найбільш навантажених частинах різального клину та характеристики міцності інструментального матеріалу [1]. Для оцінки напружень різального клину, крім геометрії різця, потрібно експериментально, за допомогою 3-х компонентного динамометра визначити сили різання або ж використовувати емпіричні залежності, які дуже приблизні. Крім того, для їх використання необхідно провести дуже багато експериментів [2].

Значно простіше вимірювати вібрації, які виникають під час різання. Вони пов'язані з процесами пластичної деформації, тертям та утворенням стружки в зоні обробки. Але всі ці процеси взаємопов'язані і встановити прямі зв'язки сил різання з параметрами вібрацій не вдається.

Для вирішення аналогічних задач останнім часом використовується підхід, заснований на побудові моделей, що враховують різноманітні невизначеності. Перспективним у цьому напрямку є застосування штучних нейронних мереж (ШНМ). Такі моделі в якості вхідних параметрів використовують сигнали акустичної емісії (АЕ), температуру та інші параметри, які можна виміряти в процесі обробки на звичайних верстатах. В Інституті надтвердих матеріалів НАН України разом з Київським національним технічним університетом ім. І. Сікорського була створена штучна нейронна мережа, яка була навчена на оригінальних експериментальних даних, отриманих за допомогою автоматизованої системи дослідження процесів різання.

Останнім часом багато авторів використовували штучні нейронні мережі під час моделювання процесів механічної обробки [3–5]. Наприклад, в роботі [5], із застосуванням штучних нейронних мереж було визначено знос різця з алмазно-твердосплавних пластин та шорсткість обробленої поверхні поршнів двигуна внутрішнього згоряння сплаву з силуміну.

Методика включала реєстрацію сигналів акустичної емісії (АЕ) із зони різання, виділення обвідної АЕ з первинного сигналу, розкладання її в спектр із застосуванням згладжування на часовому інтервалі тривалістю 2 с. Похибка визначення зносу різця у порівнянні з безпосередніми вимірами на мікроскопі «МБС-10» не перевищувала 6%, що достатньо для більшості досліджень.

В даній роботі зроблена спроба оцінити складові сили різання по параметрам вібрацій різця з зони різання при точінні загартованої сталі ШХ15 твердістю 35-60 HRC.

Опис зразків та методика випробувань

Досліджували різці з різальними вставками з 5-ти видів полікристалічних матеріалів на основі кубічного нітриду бору [6]. Проблема дослідження процесів різання для навчання ШНМ полягає в необхідності запису інформації від декількох датчиків одночасно. Як мінімум, це три складові сили різання та вібрації. Для цього використали багатоканальну вимірювальну систему дослідження працездатності різальних інструментів. Крім того, процес різання є швидкодіючим, тому для запису сигналів було використано швидкодіючий аналого-цифровий перетворювач (АЦП). Нами ця проблема була вирішена у

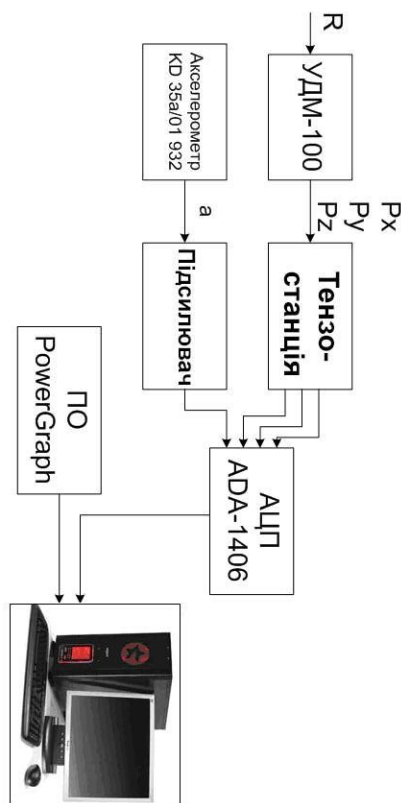


Рис. 1. Блок-схема автоматизованої вимірювальної системи

програмному продукті PowerGraph. Блок-схема автоматизованої вимірювальної системи наведено на рис. 1.

Система складається з токарного верстата підвищеної точності ТПК-125ВМ, 3-компонентного динамометра УДМ100, тензостанції «Топаз», акселерометра *KD 35a* німецької фірми *Metra Messund Frequenztechnik* (робочий діапазоном частот від 10 Гц до 10 кГц), розробленого нами узгоджувального підсилювача та АЦП ADA-1406 фірми «ХОЛІТ ДейтаСистемс» [7]. Управління АЦП також здійснювали у програмному пакеті *PowerGraph*. Цей пакет у комплекті з платою АЦП дозволив записувати сигнал з 4-х каналів із частотою опитування 50 кГц.

Було досліджено п'ять партій полікристалів кубічного нітриду бору, які відрізнялись питомою поверхнею вихідної шихти $S_{ш}$. Властивості кожного з матеріалів КНБ наведені в таблиці 1. Зі зразків було виготовлено квадратні (*SNUN*) різальні пластини, які механічно закріплювали в державці різця. Геометричні параметри різця: передній кут $\gamma = -10^\circ$; задній кут $= 10^\circ$, кут у плані - 45° .

Режими різання: глибина $t = 0,1$ мм; подача $S = 0,1$ мм/об. Швидкість різання V змінювали від 0.94 до 4.7 м/с. Оброблювальний матеріал – загартована сталь ШХ15 твердістю 50-60 HRC [6].

Таблиця 1. Характеристики і фазовий склад композитів системи *cBN-Al*, спечених при $p = 4,2$ ГПа $T = 1750$ К, $\tau = 4$ хв.

№ зразка	$S_{ш}$, м ² /г	Фазовий склад композитів, %	Твердість за Кнупом, НК, ГПа	Міцність, R_{cm} , МПа	СКВ, σ , МПа
004	2,80	87cBN+13AlN	25	357	52
024	2,20	87cBN+13AlN	26	487	63
054	1,46	87cBN+13AlN	27	580	20
074	0,71	88cBN+10AlN+1AlB ₂ +1Al	27	404	76
094	0,11	86,7cBN+10AlN+3AlB ₂ +0,3Al	28	408	80

$S_{ш}$ – питома поверхня вихідної шихти, м²/г; НК - Твердість за Кнупом, ГПа;

R_{cm} – границя міцності при розтягу, МПа; σ - середнє квадратичне відхилення міцності (СКВ), МПа, % – відсоток cBN, AlN, AlB₂ та Al, відповідно

Розробка штучної нейронної мережі

Нейронні мережі добре справляються з обробкою великих обсягів даних та дозволяють виявляти приховані закономірності вхідних сигналів, таких як вібрації, з вихідними, але вхідні сигнали містять багато шуму та мають складну зміну величини коливань у часі.

Для моделювання силових параметрів процесу різання була розроблена ШНМ у вигляді багатошарового персептрона з вхідним шаром із 511 нейронів, що відповідають числу найбільш значущих параметрів, що описують характеристики інструментального матеріалу на основі кубічного нітриду бору ($S_{ш}$, НК, R_{cm} , σ і фазовий склад композиції, % - NI та амплітудно - частотну характеристику (АЧХ) вібрацій - FR). Для реалізації ШНМ було використано середовище *TensorFlow/Keras*, яке дозволяє швидко створювати, налагоджувати та тренувати моделі без потреби вручну програмувати всі математичні операції. Це значно економить час розробки, особливо коли мережа має сотні або тисячі параметрів, і дає можливість зосередитися на побудові архітектури, а не на низькорівневій реалізації.

Розроблена нами нейронна мережа мала 6 прихованих шарів (256 в шарах 1-3, 128 в шарі 4, 64 – в шарі 5, 32 в шарі 6) та вихідний шар із 6 нейронами на виході (3 складові сил різання P_x , P_y , P_z і ще 3 – середньо квадратичні відхилення складових сил – σP_x , σP_y , σP_z (рис. 2). Процедура визначення цих коефіцієнтів (тобто, навчання ШНМ), полягала в пред'явленні ШНМ відомих як вхідних, так і вихідних даних.

Нейронна мережа мала складну архітектуру, яка включала шість прихованих шарів. Кількість нейронів у цих шарах варіювалася від 32 до 256, що дозволяло мережі поступово обробляти та трансформувати вхідні дані на різних рівнях абстракції. На вихідному шарі було розміщено шість нейронів, які відповідали за прогнозування ключових параметрів: три складові сили різання (P_x , P_y , P_z) та три їх середньоквадратичні відхилення (σP_x , σP_y , σP_z). Графічне представлення початкової структури ШНМ наведено на рисунку 2.

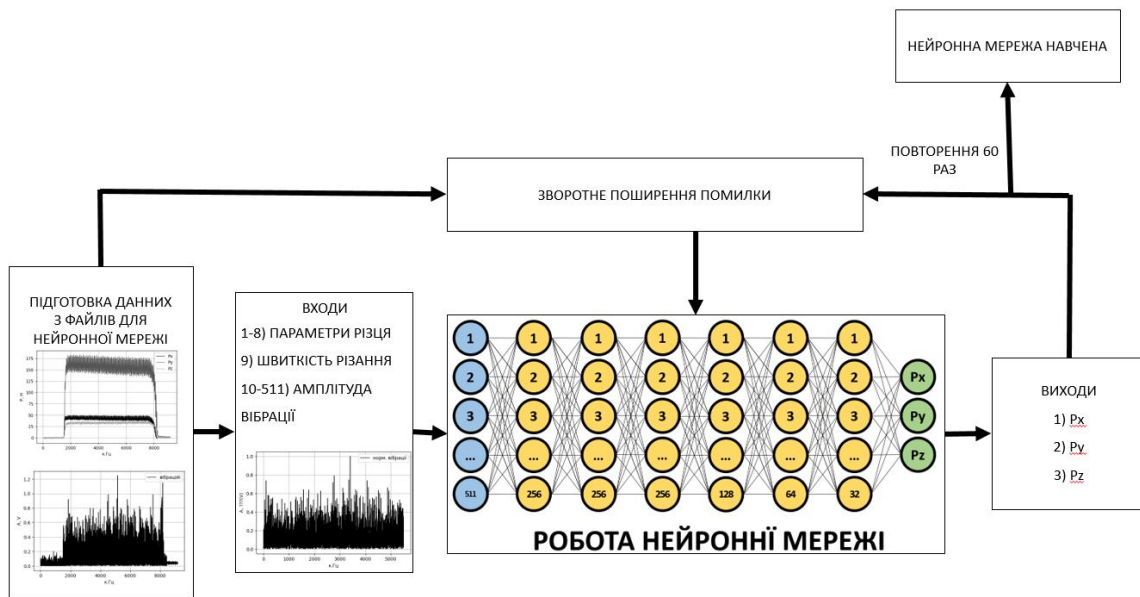


Рис. 2. Структура штучної нейронної мережі ШНМ

Ми прийняли підхід, коли кожен нейрон обчислює свій вихід на основі вхідних сигналів і вагових коефіцієнтів. Цей процес називається прямим поширенням. Після отримання виходу мережа порівнює його з відомим цільовим значенням, обчислюючи абсолютну похибку (різницю між прогнозом і реальним значенням). Ця похибка є найбільш важливою для подальшого навчання. Цей цикл повторюється багаторазово, поки мережа не досягне прийнятного рівня похибки або не буде виконано певну кількість ітерацій.

Для створення ШНМ на мові *Python* використовували високорівневі бібліотеки *TensorFlow*. Процедура навчання та оцінки точності моделі передбачала такі важливі аспекти, як кількість епох навчання, розмір пакетів даних та методи оцінки точності.

В нашому випадку навчання проходило за 60 епох, оскільки подальше збільшення тривалості навчання ШНМ не призводило до покращення результатів.




Рис. 3. Різець із акселерометром (а), який закріплено у динамометрі УДМ100 (б)

Для навчання ШНМ та практичної реалізації різець встановлювали у динамометр УДМ100, на різець закріплювали акселерометр *KD 35a* німецької фірми *Metra Messund Frequenz technik*, який дозволяв вимірювати прискорення вібрацій (рис. 3, а).

Акселерометр *KD 35a* є п'єзоелектричним датчиком з великим вихідним опором. Датчик закріплювали у нижній частині різця, максимально наближено до зони різання (рис. 3, б).

Навчання та використання штучної нейронної мережі

Результат роботи ШНМ прямо залежить від точності та якості вагових коефіцієнтів синоптичних зв'язків. Процедура визначення цих коефіцієнтів, відома як навчання ШНМ, вимагає пред'явлення мережі великих обсягів як вхідних, так і відповідних їм вихідних даних.

Навчання ШНМ починалось з імпорту зібраних експериментальних даних, які включали інформацію про три складові сили різання, отриману з 3-компонентного динамометра, а також амплітуди вібрації, зареєстровані акселерометром для кожного різця та режиму різання. Також додавали характеристики та фазовий склад ПКНБ для кожної з різальних пластин (табл. 1).

Для полегшення подальшої обробки та підвищення релевантності даних, було здійснено обрізку частин даних до та під час врізання та виходу різця з деталі. Це дозволило сфокусуватися на стабільній фазі процесу різання, мінімізуючи вплив перехідних процесів.

Крім того, для зменшення шуму у даних про вібрації та сили було застосовано згладжування за допомогою функції ковзного середнього. Цей метод належить до класу технік, де для розрахунку кожного нового значення використовується декілька послідовних значень вхідного сигналу, що розміщуються у вікні фіксованої ширини N . У нашому випадку ширина вікна становила 501 точку. Під час аналізу сигналу це вікно поступово зміщується вздовж часової осі, формуючи так зване ковзне вікно. Згладжування виконувалося програмно в *Python*.

Для навчання ШНМ 1 проводили нормалізацію даних від 0 до 1 за формулою 1, яка допомогла уникнути ситуації, коли одні параметри мають значно більші значення, ніж інші. Це підвищує точність моделі. Крім того, ШНМ швидше знаходить оптимальні ваги, коли вхідні дані знаходяться в межах від 0 до 1 або від -1 до 1 через те, що великі значення можуть призводити до переповнення та неточностей при обчисленнях. Також рівномірно масштабовані дані сприяють більш ефективному оновленню ваг під час оптимізації, через що ШНМ дає кращі результати на нормалізованих даних.

$$\chi_{norm} = \frac{\chi - \chi_{min}}{\chi_{max} - \chi_{min}}, \quad (1)$$

де χ_{min} та χ_{max} - мінімальне та максимальні значення величин у виборці.

Для уникнення упередженості під час навчання та підвищення здатності моделі до узагальнення, всі вхідні дані проходили попереднє перемішування перед подачею на вхід штучної нейронної мережі [8].

Після отримання вихідних даних мережа порівнює їх з відомим цільовим значенням (фактично вимірними силами різання та їх дисперсіями), обчислюючи похибку — різницю між прогнозними значеннями моделі та реальними (вимірюваними) значеннями. Ця похибка є найбільш важливим показником для подальшого навчання. На основі обчисленої похибки мережа коригує свої вагові коефіцієнти через процес, відомий як зворотне поширення помилки (*backpropagation*). Цей механізм дозволяє моделі поступово зменшувати похибку та покращувати свої прогнози на наступних ітераціях навчання. Цикл прямого поширення та зворотного поширення повторюється багаторазово, поки мережа не досягне прийнятної рівня точності або не буде виконано певну кількість ітерацій (epoch). Таким чином, навчання ШНМ базується на поступовому вдосконаленні її здатності до узагальнення через корекцію вагових коефіцієнтів на основі помилок у прогнозах.

Оптимізація кількості нейронів та шарів

На основі попередніх досліджень та серії тестових експериментів було обрано оптимальну кількість нейронів у прихованих шарах: 256, 256, 256, 128, 64, 32. Вхідний шар ШНМ налічував 511 нейронів:

- № 1-8: Характеристики ПКНБ (таблиця 1).
- № 9: Швидкість різання.
- № 10-511: Амплітуди вібрації.

Під час оптимізації ШНМ було виявлено кращу структуру, яка складалася лише з чотирьох шарів нейронів, по 16 нейронів у кожному шарі. Між кожною парою шарів було додано спеціальні шари для підвищення стабільності та узагальнюючої здатності моделі:

- Шари нормалізації (*tf.keras.layers.BatchNormalization*). Ці шари виконують нормалізацію вхідних значень для кожного шару, що значно прискорює процес навчання та стабілізує його. Це зменшує чутливість мережі до початкових параметрів та коливань у розподілі вхідних даних.
- Шари дропаут (*tf.keras.layers.Dropout(0.3)*). Використання шару *Dropout(0.3)* означає, що під час навчання випадковим чином "відключається" (ігнорується) 30% нейронів поточного шару. Цей метод є ефективним способом запобігання перенавчанню моделі, сприяючи її загальній здатності до узагальнення на невидимих даних.

Dropout і *Batch Normalization* допомагають уникнути перенавчання [8]. Уявімо, що модель вчиться зачувати приклади напам'ять — тоді вона не зможе працювати з новими даними. *Dropout* "відключає" випадкові нейрони, щоб змусити мережу навчатися узагальнювати, а не запам'ятовувати. *Batch Normalization* стабілізує навчання, зменшуючи випадкові стрибки у навчанні, завдяки чому мережа працює більш надійно.

Моделю була створена на мові програмування *Python* з використанням програмної бібліотеки з відкритим кодом *TensorFlow/Keras*, розробленої компанією *Google*. Використання цієї високорівневої бібліотеки дозволило значно спростити розробку та скористатися її перевагами, такими як підтримка розподілених обчислень, що дало змогу навчати нейронні мережі на великих об'ємах даних за прийнятний час, розподіляючи обчислення по багатьох серверах.

Програму компілювали з використанням оптимізатора *Adam* та функції втрат за середнім значенням абсолютної похибки (*Mean Absolute Error (MAE)*). *MAE* є хорошою метрикою для оцінки моделей, які прогнозують числові значення, оскільки вона прямо відображає середню абсолютну різницю між прогнозованими та фактичними значеннями. Процедура навчання та оцінка точності моделі передбачала такі важливі параметри, як кількість епох навчання, розмір пакетів даних та методи оцінки точності.

Навчання проходило протягом 60 епох і в кінці періоду цього ШНМ перестала покращувати свої результати. Під час навчання використовувався змінний розмір пакетів даних (*batch_size*) від 512 до 4096, тобто ШНМ навчалася не на одному прикладі за один раз, а одразу на пакетах, що містили до 4096 прикладів. Такий підхід дозволив більш ефективно навчатися, оскільки модель не змінювала свої параметри по черзі для кожного прикладу, а одразу наближалася до правильного результату на основі агрегованої інформації. Зі збільшенням *batch_size* підвищується ефективність використання апаратних ресурсів за рахунок того, що великі пакети даних легше розподіляти між обчислювальними блоками центрального процесора (*CPU*) та графічного процесора (*GPU*), що дозволило краще завантажувати обчислювальну потужність обладнання. В кінці процесу навчання *batch_size* був зменшений до 512 для збільшення можливості штучному інтелекту покращити свою роботу, оскільки менші пакети можуть сприяти більш тонкому налаштуванню моделі на останніх етапах навчання [9].

Графік зменшення похибки ШНМ 1 під час навчання представлено на рис. 4.

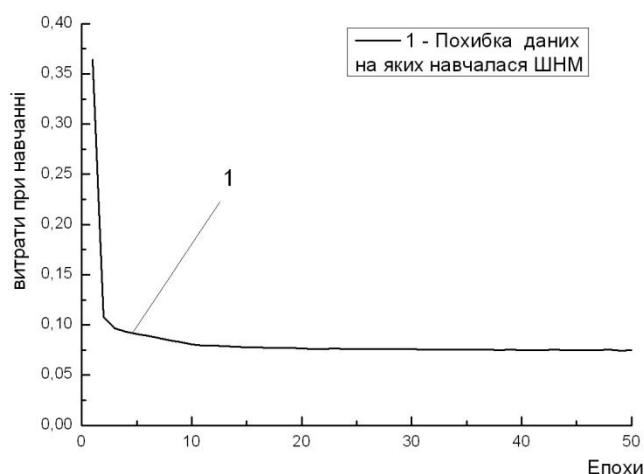


Рис. 4. Графік зменшення похибки ШНМ

Для оцінки точності ШНМ було використано абсолютну похибку, що дозволило одразу побачити всі похибки в реальних величинах та порівняти їх між собою.

Оцінка результатів показала, що середня абсолютна похибка на тренувальних даних була досить низькою – від 0.8 до 4.3 Н для сил та від 0.07 до 0.33 Н для їх дисперсій. Відносні похибки склали від 2.9% до 9.2%, що вказує на хорошу точність моделі в межах навчальної вибірки. Проте на нових даних, які не були задіяні у навчанні, модель показала більші

відносні похибки, а саме з середньою відносною похибкою прогнозування складових сил різання та їх дисперсій 26%, що свідчить про певну обмеженість у здатності до узагальнення в умовах сильної варіативності вхідних параметрів або не ідентичності наборів даних.

При обробці різцями з надтвердих матеріалів важливим фактором є надійність різального інструменту. Надтверді матеріали характеризуються значним розкидом параметрів міцності, що суттєво впливає на ймовірність руйнувань інструменту під час експлуатації. Значний розкид міцності зумовлений особливостями технології їх виготовлення, нестабільності структури матеріалу по об'єму, а також умовами експлуатації. Внаслідок цього забезпечення стабільності та працездатності інструменту є складним завданням.

Працездатність інструменту розглядається як його здатність ефективно виконувати обробку матеріалу, зберігаючи при цьому необхідний рівень якості, без передчасних поломок, надмірного зносу чи втрати працездатності якості обробленої поверхні. Для практичного застосування важливо не лише визначати поточний стан інструменту, а й мати можливість прогнозувати ймовірність його руйнування.

У рамках цієї роботи було використано метод, що базується на аналізі прогнозованих значень сил різання та їх дисперсій, які формує штучна нейронна мережа. Цей підхід дозволяє оцінити ймовірність руйнування інструменту шляхом математичного моделювання взаємодії між напруженнями, що виникають під час обробки (S_R), та характеристиками міцності матеріалу інструменту (S_p).

Математичний апарат розрахунку ймовірності руйнування визначається як площа перетину двох функцій розподілу ймовірностей — функції розподілу напружень ($f(S_R)$) та функції розподілу міцності інструменту ($f(S_p)$). Ці функції описують відповідно розподіл ймовірностей випадкових змінних S_R і S_p , що характеризують напруження на поверхнях інструменту та характеристики міцності матеріалу різця S_p .

Для точного визначення ймовірності руйнування застосовується інтегральна формула 2, яка обчислює площу взаємного перетину диференціальних функцій розподілу напружень на передній та на задній гранях різця з розподілом міцності матеріалу вставки:

$$J = J1 + J2 = \int_0^{S_d} f(S_p) dS + \int_{S_d}^{\infty} f(S_R) dS \quad (2)$$

Цей інтеграл відображає загальну ймовірність того, що навантаження, прикладені до інструменту, перевищать його міцність, що є прямим критерієм для прогнозування руйнування.

Практичне значення розрахунку - визначення ймовірності руйнування інструменту на основі статистичних характеристик сили різання та міцності дозволяє приймати обґрунтовані та наглядні рішення щодо оптимізації режимів обробки та своєчасної заміни або ремонту інструменту. Такий підхід сприяє підвищенню надійності виробничих процесів, зниженню витрат на простої та заміну обладнання, а також покращенню якості оброблюваних виробів.

Отримані в роботі прогнози сили різання та їх дисперсії, які генеровані штучною нейронною мережею слугують вхідними даними для статистичного моделювання ймовірності руйнування. Це робить запропонований метод ефективним інструментом для діагностики технічного стану інструменту в реальному часі.

В Інституті надтвердих матеріалів НАН України розроблений спеціалізований програмний пакет *VarTool*, реалізований у середовищі *Mathcad*, що дозволяє виконувати ці обчислення на основі вхідних технологічних, геометричних та фізико-механічних параметрів [2]. Використання даної методики та програмного інструменту дозволяє інженеру-технологу або досліднику отримати кількісну оцінку надійності інструмента у конкретних умовах обробки, враховуючи як технологічні, так і матеріалознавчі фактори. Це відкриває перспективи для гнучкого керування параметрами різання та адаптивного вибору інструментів з підвищеною довговічністю.

Для оцінки точності роботи побудованої штучної нейронної мережі (ШНМ) було проведено порівняння результатів розрахунку ймовірності руйнування різального інструменту, отриманих безпосередньо з експериментальних (вимірних) сил різання, із відповідними результатами, які генеровані ШНМ на основі прогнозованих сил та дисперсії.

Аналіз похибок показав, що при відповідній кількості навчальних даних модель демонструє прийнятну точність — середня абсолютна похибка прогнозування ймовірності руйнування різального інструменту відсотки не перевищує 11,44%. Це підтверджує ефективність застосування нейронних мереж для задач технічної діагностики та прогнозування залишкового ресурсу інструменту, відкриваючи можливості для впровадження таких підходів у системи автоматизованого контролю в режимі реального часу.

Висновки

Проведені дослідження підтверджують доцільність застосування штучних нейронних мереж для діагностики стану різців з надтвердих матеріалів через прогнозування складових сил різання та їх середньоквадратичних відхилень за даними про вібрації під час різання.

Середня відносна похибка при використанні ШНМ для прогнозування складових сил різання не більше 12%, що дозволяє використовувати ШНМ в дослідженнях працездатності різальних інструментів з ПКНБ.

Результати дослідження відкривають нові перспективи подальшого розвитку адаптивних систем керування верстатами на основі контролю вібрацій в процесі механічної обробки.

L. Devin, M. Bezhenar, S. Rychev¹, N. Tishchenko², O. Hriazev, V. Nechyporenko²

¹*V. Bakul Institute for superhard materials NASU Ukraine*

²*National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute»*

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR EVALUATING THE PERFORMANCE OF CUTTING TOOLS MADE OF PCBN

The methodology and results of the study of the components of cutting forces, acoustic emission and vibrations during the finish turning of hardened steel ShKh15 (HRC 50–60) are presented. To find the relationship between the components of cutting forces and vibrations, an approach based on the creation of

models that take into account various uncertainties was used. For this purpose, the developed artificial neural network (ANN) was used. Turning cutters with cutting inserts made of 5 types of polycrystalline materials based on cubic boron nitride were studied. The developed neural network initially had a complex architecture that included six hidden layers. The number of neurons in these layers varied from 32 to 256. The average relative error when using ANN was no more than 12%, which allows using ANN in real time in studies of the performance of cutting tools with PCNB. The results of the study open new prospects for the further development of adaptive machine tool control systems based on vibration control in the machining process.

Key words: tool condition diagnostics, artificial neural networks, polycrystals of superhard materials, cubic boron nitride, vibrations, acoustic emission, cutting force components, probability of fracture, adaptive cutting process control systems.

Література

1. Мазур М.П., Внуков Ю.М., Доброскок В.Л., Залога В.О., Новосьолов Ю.К., Якубов Ф.Я. Основи теорії різання матеріалів : підручник / під заг. ред. М.П. Мазура. Львів: Новий Світ-2000, 2010. 422 с.
2. Девін Л. М., Беженар М. П., Стахнів М. Є. Прогнозування ймовірності руйнування різців із полікристалів надтвердих матеріалів при точінні загартованої сталі. *Проблеми міцності*. 2022. № 3. С. 90–99.
3. Девін Л. М., Найденко О. Г. Аналіз акустичної емісії при точінні алюмінієвих сплавів різцями з АТП із використанням нейронних мереж. *Різання та інструменти в технологічних системах*. Зб. тр. ХІІІ. Вип. 64. Харків: НТУ «ХПІ», 2003. С. 53–58.
4. Новіков М. В., Девін Л. М., Стахнів М. Є., Лисенко К. О. Особливості програмного управління аналого-цифровим перетворювачем при експериментальних дослідженнях сили різання. *Наукоємні технології*. 2009. № 2. С. 94–97.
5. Briceno J. F., El-Mounayri H., Mukhopadhyay S. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process. *International Journal of Machine Tools and Manufacture*. 2002. Vol. 42, N 6. P. 663–674.
6. Ezugwu E. O., Fadare D. A., Bonney J., Da Silva R. B., Sales W. F. Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network. *International Journal of Machine Tools and Manufacture*. 2005. Vol. 45, N 12–13. P. 1375–1385.
7. Jaiswal S. What is Normalization in Machine Learning? A Comprehensive Guide to Data Rescaling. 04.01.2024. URL: <https://www.datacamp.com/tutorial/normalization-in-machine-learning>.
8. Sankaran S., Wang H., Guilhoto L. F., Perdikaris P. On the impact of larger batch size in the training of Physics Informed Neural Networks. *Workshop on Machine Learning and the Physical Sciences: Proceeding of the 36th Conference on Neural Information Processing System*, 3 December 2022. New Orleans, United States. P. 1–8.

Надійшла 14.08.25

References

1. Mazur, M. P. (Ed.). (2010). *Osnovy teorii rizannia materialiv [Fundamentals of the theory of material cutting]*. Novyi Svit-2000 [in Ukrainian].
2. Devin, L. M., Bezhenar, M. P., & Stakhniv, M. Ye. (2022). Prediction of the probability of tool failure from polycrystalline superhard materials during hard turning. *Strength of Materials*, (3), 90–99.
3. Devin, L. M., & Naidenko, O. H. (2003). Analiz akustychnoi emisii pry tochinni aliuminiievkykh splaviv rizsiamy z ATP iz vykorystanniam neironnykh merezh [Analysis

- of acoustic emission during turning of aluminum alloys using PCD tools and neural networks]. *Proc. of NTU "KhPI". Cutting and tools in technological systems*, (64), 53–58 [in Ukrainian].
- Novikov, M. V., Devin, L. M., Stakhniv, M. Ye., & Lysenko, K. O. (2009). Osoblyvosti prohramnoho upravlinnia analoho-tsyfrovyim peretvoriuvachem pry eksperymentalnykh doslidzhenniakh syly rizannia [Features of software control of an analog-to-digital converter in experimental studies of cutting force]. *Science-Intensive Technologies*, (2), 94–97 [in Ukrainian].
 - Briceno, J. F., El-Mounayri, H., & Mukhopadhyay, S. (2002). Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process. *International Journal of Machine Tools and Manufacture*, 42(6), 663–674.
 - Ezugwu, E. O., Fadare, D. A., Bonney, J., Da Silva, R. B., & Sales, W. F. (2005). Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network. *International Journal of Machine Tools and Manufacture*, 45(12–13), 1375–1385.
 - Jaiswal, S. (2024, January 4). *What is Normalization in Machine Learning? A Comprehensive Guide to Data Rescaling*. (b. d). <https://www.datacamp.com/tutorial/normalization-in-machine-learning>
 - Sankaran, S., Wang, H., Guilhoto, L. F., & Perdikaris, P. (2022). On the impact of larger batch size in the training of Physics Informed Neural Networks. *DLDE Workshop at the 36th Conference on Neural Information Processing Systems (NeurIPS 2022)*. (p. 1–8).

УДК 621.9.025

DOI: 10.33839/2708-731X-28-1-412-421

С.А. Клименко, член-кор. НАН України; **С.Ан. Клименко**, **Ю.О. Мельничук**,
М.Ю. Копейкіна, **А.О. Чумак**, **А.С. Манохін**, кандидати технічних наук

*Інститут надтвердих матеріалів ім. В.М. Бакуля НАН України,
вул. Автозаводська 2, 04074, м. Київ, atmi@meta.ua*

ПРАЦЕЗДАТНІСТЬ РІЗАЛЬНОГО ІНСТРУМЕНТУ, ОСНАЩЕНОГО КОМПОЗИТАМИ З ВИСОКИМ ВМІСТОМ cBN, ПРИ ТОЧІННІ ЗАГАРТОВАНОЇ СТАЛІ З УДАРНИМ НАВАНТАЖЕННЯМ

У статті досліджено працездатність різального інструменту, оснащеного полікристалічними композитами на основі кубічного нітриду бору (PcBN) з високим вмістом cBN (до 97%), під час точіння загартованої сталі ХВГ за умов ударного навантаження. Проведено експериментальні дослідження впливу геометричних параметрів інструменту, зокрема кута нахилу різальної кромки ($\lambda = 0-50^\circ$), на характер зношування інструменту, стабільність процесу різання та якість обробленої поверхні. Встановлено, що використання інструментів із $\lambda = 40^\circ$ забезпечує найвищу стійкість (до 50–60 хв) та дозволяє здійснювати ефективну обробку при підвищених подачах ($S = 0,40-0,65$ мм/об). Отримані результати підтверджують доцільність застосування інструменту із PcBN косокутної конструкції для високопродуктивного точіння загартованих залізовуглецевих сплавів в умовах динамічного навантаження.