

Міністерство освіти і науки України
Національний технічний університет
«Дніпровська політехніка»

Механіко-машинобудівний

(факультет)

Кафедра конструювання, технічної естетики і дизайну
(повна назва)

ПОЯСНЮВАЛЬНА ЗАПИСКА
кваліфікаційної роботи ступеня бакалавра

(бакалавра, спеціаліста, магістра)

Студента Овчаренко Івана Максимовича
(ПІБ)

академічної групи 132-22ск-2 ММФ
(шифр)

спеціальності 132 Матеріалознавство
(код і назва спеціальності)

спеціалізації за освітньо-професійною програмою _____
(за наявності)

«Промислова естетика і сертифікація матеріалів та виробів»
(офіційна назва)

на тему Розробка алгоритму розпізнавання мікроструктури сталі за допомогою нейронної мережі
(назва за наказом ректора)

Керівники	Прізвище, ініціали	Оцінка за шкалою		Підпис
		рейтинговою	інституційною	
кваліфікаційної роботи	Федоряченко С.О.			
розділів:				
Аналіз стану питання та постановка задач роботи	Федоряченко С.О.			
Функціональний аналіз та моделювання об'єкта розробки	Федоряченко С.О.			
Інженерно-технологічний	Ротт Н.О.			
Експлуатаційний	Федоряченко С.О.			
Рецензент				
Нормоконтролер	Вернер І.В.			

Дніпро
2025

ЗАТВЕРДЖЕНО:
завідувач кафедри
конструювання, технічної
естетики і дизайну
(повна назва)

_____ Федоряченко С.О.
(підпис) (прізвище, ініціали)

« _____ » _____ 2023 року

ЗАВДАННЯ
на кваліфікаційну роботу
ступеню бакалавра
(бакалавра, спеціаліста, магістра)

студенту Овчаренко Івану Максимовичу академічної групи 132-22ск-2 ММФ
(прізвище та ініціали) (шифр)

спеціальності 132 Матеріалознавство
спеціалізації _____

за освітньо-професійною програмою «Промислова естетика і сертифікація
матеріалів та виробів»

на тему Розробка алгоритму розпізнавання мікроструктури сталі за
допомогою нейронної мережі затверджену наказом ректора НТУ
«Дніпровська політехніка» від 14.05.2025р. №369-с

Розділ	Зміст	Термін виконання
Аналіз стану питання та постановка задач роботи	Аналіз стану питання та постановка задач роботи	20.05.2025
Функціональний аналіз та моделювання об'єкта розробки	Функціональний аналіз об'єкту розробки, визначення алгоритмів	25.05.2025
Інженерно-технологічний	Розробка моделі навчання застосунку, аналіз отриманих результатів	10.06.2025
Експлуатаційний	Обґрунтування вимог до використання застосунку та методів навчання на еталонних зображеннях	16.06.2025

Завдання видано _____
(підпис керівника)

Федоряченко С.О.
(прізвище, ініціали)

Дата видачі 14.05.2025

Дата подання до екзаменаційної комісії 24.06.2025

Прийнято до виконання _____

Овчаренко І.М.

РЕФЕРАТ

Пояснювальна записка: ___ с, ___ рис. ___ табл., ___ джерело.

ПРОГНОЗУВАННЯ МІКРОСТРУКТУРИ СТАЛІ, ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ, КЛАСИФІКАЦІЯ МЕТАЛУРГІЙНИХ ФАЗ, МАШИННЕ НАВЧАННЯ, АНАЛІЗ МІКРОСТРУКТУРНОГО ЗОБРАЖЕННЯ, КІНЕТИКА ПЕРЕТВОРЕННЯ В СТАЛІ

Мета кваліфікаційної роботи – обґрунтування та розробка алгоритму інтелектуального аналізу мікроструктури сталі та визначення потенційних зон неметалевих включень.

Предмет дослідження – процес аналізу мікроструктури та неметалевих включень у вуглецевих сталях.

Об'єкт дослідження – високовуглецеві сталі та сплави, неметалеві включення у яких схильні до зниження фізико-механічних характеристик виробу.

ЗМІСТ

ВСТУП	5
1 АНАЛІЗ СТАНУ ПИТАННЯ ТА ПОСТАНОВКА ЗАДАЧ РОБОТИ	6
1.1 Аналіз умов виникнення неметалевих включень	6
1.2 Архітектура інтелектуального інструменту для прогнозування мікроструктури сталі.....	8
1.3 Аналіз необхідності використання штучного інтелекту в матеріалознавстві	9
1.4 Вплив інтеграції технології ШІ на виробництво та контроль якості продукції металургійного виробництва	9
1.5 Прогнозування мікроструктури сталі на основі складу та режиму термообробки	11
1.6 Доступність даних та підготовка вхідних ознак	16
1.7 Навчання та валідація моделей прогнозування мікроструктури.....	18
1.8 Постановка задач дослідження	19
2 ФУНКЦІОНАЛЬНИЙ АНАЛІЗ ТА МОДЕЛЮВАННЯ ОБ'ЄКТА РОЗРОБКИ	20
2.1 Визначення методик математичного опису зображень мікроструктури сталі та функціонально-вартісний аналіз розробки	20
2.2 Аналіз архітектури моделей розпізнавання зображень за функціональним змістом	21
2.3 Визначення методик попередньої обробки зображень.....	24
2.4 Математичне описання процесу аналізу зображення	25
2.5 Автоматизована реалізація методу перетинів	26
2.6 Інтеграція планіметричного методу сегментації зерен	27
2.7 Технологічна реалізація.....	27
2.8 Висновки за розділом.....	28
3 ІНЖЕНЕРНО-ТЕХНОЛОГІЧНИЙ РОЗДІЛ	30
3.1 Аналіз впливу термічних напружень поблизу включень	30
3.2 Вплив неметалевих включень на механізми деформації та руйнування сталей при різних температурах	32
3.3 Постановка інженерної задачі формування моделі	35
3.4 Навчання моделей та оцінка точності визначення структури	36
3.5 Візуалізація та перевірка результатів.....	43
3.6 Налаштування зображення, за для коректного аналізу даних	45
3.7 Характеристика включень та виведення результатів аналізу	47
Висновок за розділом.....	48
4 ЕКСПЛУАТАЦІЙНИЙ РОЗДІЛ.....	50
4.1 Аналіз області застосування програмного застосунку аналізу сталі	50
4.2 Правила побудови датасету та навчання моделі.....	51
4.3 Методи перевірки якості	52
4.4 Висновок за розділом.....	54
ЗАГАЛЬНИЙ ВИСНОВОК.....	55
СПИСОК ЛІТЕРАТУРИ.....	58

ВСТУП

Точне прогнозування мікроструктури сталі має вирішальне значення для забезпечення бажаних механічних властивостей у промисловому застосуванні. Це дослідження інтегрує моделі металургійного перетворення в згортову нейронну мережу (CNN) для класифікації та кількісного аналізу мікроструктур сталі, включаючи ферит, перліт, бейніт і мартенсит. Модель використовує розпізнавання зернистої структури на основі зображень у поєднанні з явними математичними співвідношеннями, такими як рівняння Холла-Петча для межі текучості, рівняння Койстінена-Марбургера для мартенситного перетворення та рівняння Аврамі для прогнозування частки фази фериту та перліту. Впроваджуючи ці зв'язки в системі машинного навчання на основі Python, мережа не тільки класифікує сталеві фази, але й оцінює розмір зерен, кінетику трансформації та механічні властивості.

Розроблений підхід забезпечує точність понад 90% у класифікації мікроструктури та дозволяє прогнозувати металургійні характеристики в режимі реального часу на основі зображень мікроструктури. Це дослідження відкриває новий шлях для обчислювальної матеріалознавства шляхом інтеграції керованих даними нейронних мереж із фундаментальними фізичними моделями.

1 АНАЛІЗ СТАНУ ПИТАННЯ ТА ПОСТАНОВКА ЗАДАЧ РОБОТИ

1.1 Аналіз умов виникнення неметалевих включень

Для фаз впровадження характерна наявність двох решіток - металевої та неметалевої, причому металева підрешітка, як правило, відмінна від решітки металу-розчинника, тому вони близькі до хімічних сполук. У всіх фазах впровадження атоми неметалу заповнюють незначну частину порожнин у решітці металу.

Кристалічні ґратки фаз впровадження формуються, як і в щільно упакованих металах, у вигляді укладок атомних шарів із послідовністю АВАВАВ... або АВСАВС. Атоми неметалів О, С, N, Н розташовуються в проміжках між шарами атомів металу, і хімічні зв'язки, зумовлені їхньою присутністю, сприяють зчепленню металевих шарів і ускладнюють легке ковзання при деформації. У багатьох оксидів, карбідів, нітридів спостерігається структура типу NaCl, яка реалізується шляхом впровадження атомів неметалу в ґратку металу (наприклад, FeO, CoO), або ґратка типу CaF₂. Ці ґратки відрізняються лише розташуванням у них атомів неметалу, тоді як ґратка металевих атомів у них однакова.

Залежно від умов кристалізації, природи включень та подальшої обробки сталі, у включеннях можуть формуватися межі з малим, середнім або великим кутом між зернами, причому останні — як спеціального, так і загального типу. Поведінка зерен та субмеж у включеннях така ж, як і в металах та металевих сплавах. Межі всіх типів притягують атоми неметалів, що призводить до виникнення сегрегацій і, відповідно, обмеження рухливості меж. У багатофазних включеннях наявні міжфазні межі, які можуть бути когерентними або некогерентними залежно від природи та умов кристалізації фаз. На рис. 1.1, а у включенні видно ямки травлення від дислокацій, а також субмежі. Неметалеві включення є полікристалічними фазами, і через свою дисперсність мають дуже малі розміри зерен, тому багато з них можна віднести до нанокристалічних фаз у сталях (рис. 1.1, б). Ці фази мають велику

Об'ємні дефекти у включеннях можуть бути пов'язані зі скупченням вакансій, виділенням атомів неметалів із утворенням молекул газу та термічними напруженнями. Для аморфних включень характерний ближній порядок у розташуванні атомів (рис. 1.1, в). Основним структурним елементом є кластер ікосаедра з осями симетрії п'ятого порядку або кластери іншої симетрії, яка забороняє періодичність упаковки. В аморфному матеріалі також можуть бути мікро кристаліти розміром 2,0...2,5 нм. В аморфних включеннях, як і в кристалічних, наявні дефекти атомної будови. Вакансії та дислокації в аморфних матеріалах не підвищують внутрішню енергію, як у кристалах, а навпаки — знижують її. В аморфних включеннях також виникають дисклінації, причому густина дисклінаційних петель, здатних випромінювати та поглинати дислокації, є досить високою. Оскільки суть моделей аморфного стану полягає у введенні певної структурної одиниці, за допомогою якої заповнюється тривимірний простір (ікосаедри, додекаедри), такі конфігурації атомів можуть бути реалізовані за умови введення дисклінацій.

1.2 Архітектура інтелектуального інструменту для прогнозування мікроструктури сталі

Мікроструктура сталі, що характеризується просторовою організацією зерен та фаз у твердому металі, визначає ключові фізико-механічні властивості матеріалу. З огляду на складність цих структур та їхню залежність від технологічних параметрів, актуальною є задача створення автоматизованих інструментів для прогнозування мікроструктури та аналізу зображень, отриманих методом оптичної або електронної мікроскопії.

Сучасні підходи до вирішення подібних задач базуються на методах глибокого навчання, зокрема згорткових нейронних мереж (CNN) та багатошарових перцептронів (MLP), реалізованих у середовищі Python із використанням бібліотек PyTorch, TensorFlow, scikit-learn, OpenCV та ін. Метою даного розділу є обґрунтування архітектури системи, здатної здійснювати класифікацію фазового складу сталі, аналіз мікрофотографій та

побудову гібридних моделей на основі поєднання числових і візуальних даних.

1.3 Аналіз необхідності використання штучного інтелекту в матеріалознавстві

У сучасних дослідженнях все частіше згадується про застосуванні штучного інтелекту у матеріалознавстві. Зокрема, у статті Ентоні Ю-Тунг Вана та команди (2020), опублікованій у журналі «Chemistry of Materials», наводяться два ключові аргументи на користь цього підходу:

Класичні методи прогнозування властивостей матеріалів, що застосовуються на виробництвах, часто дають значну похибку (20–30%). Однак застосування методів машинного навчання, таких як графові неймережі (GNN), дозволяє знизити цей показник до 5%. Подібна точність прогнозування означає, що ШІ ефективніше аналізує експлуатаційні характеристики матеріалів."

Віртуальні моделі на основі ШІ дають змогу відмовитися від частини лабораторних тестів, скорочуючи їх кількість на 40–60%. Для галузей, де експерименти потребують великих фінансових або часових витрат (наприклад, у розробці нових сплавів або полімерів), це є істотним перевагою.

1.4 Вплив інтеграції технології ШІ на виробництво та контроль якості продукції металургійного виробництва

Автоматизуючи такі завдання, як розрахунок розміру зерен та виявлення включень, компанії можуть значно скоротити час та трудозатрати, необхідні для контролю якості та оптимізації процесів. Швидший та точніший аналіз призводить до зменшення простоїв виробництва та меншої кількості відходів, що безпосередньо знижує операційні витрати.

Покращене прогнозування мікроструктури дозволяє краще контролювати властивості матеріалів. Такий покращений контроль якості мінімізує ризик

дефектів, зменшує потребу в переробці або відкликанні продукції та призводить до більшої узгодженості характеристик продукції. На конкурентних ринках краща якість продукції призводить до покращення репутації на ринку та потенційно до вищих продажів.

Програмне забезпечення дозволяє компаніям ефективніше збирати та аналізувати дані. Визначаючи оптимальні параметри обробки для бажаних мікроструктурних властивостей, виробники можуть точно налаштувати свої виробничі процеси. Це призводить до економії енергії, зменшення споживання матеріалів та загального підвищення продуктивності, тим самим підвищуючи прибутковість.

Компанії, які впроваджують такі передові аналітичні інструменти, можуть швидше впроваджувати інновації. Здатність точно прогнозувати та контролювати мікроструктуру забезпечує конкурентну перевагу, дозволяючи компаніям відповідати суворим галузевим стандартам та відкривати нові ринкові можливості.

Автоматизація мікроструктурного аналізу мінімізує необхідність ручного обробки небезпечних матеріалів або впливу потенційно небезпечних середовищ. Покращені протоколи безпеки знижують ризик нещасних випадків, створюючи безпечніше робоче середовище для працівників.

Завдяки покращеному контролю процесів та скороченню відходів компанії можуть рухатися до більш сталого виробництва. Ефективне використання ресурсів та зниження викидів не лише покращують прибуток, але й позитивно впливають на здоров'я громади та екологічну стійкість.

Оскільки компанії стають більш конкурентоспроможними та розширюються завдяки підвищенню ефективності та якості продукції, існує потенціал для створення робочих місць та економічного зростання. Хвильовий ефект технологічних інновацій часто призводить до збільшення інвестицій у дослідження та розробки, створюючи більше можливостей у місцевій економіці.

1.5 Прогнозування мікроструктури сталі на основі складу та режиму термообробки

Класифікація мікроструктурних станів сталі - феритно-перлітних, мартенситних, бейнітних - може бути реалізована як задача багатокласової класифікації на основі вхідних параметрів: хімічного складу, температури нагрівання та охолодження, тривалості витримки тощо. У загальному випадку застосовуються два підходи:

- багатосарові перцептрони (MLP) для аналізу числових параметрів;
- згорткові нейронні мережі (CNN) для класифікації мікроструктур за зображеннями.




Рисунок 1.2 – Мікроструктури сталі

MLP-моделі реалізують передбачення типу мікроструктури або фазового складу шляхом побудови відповідності між багатовимірним простором ознак і класом вихідної мікроструктури. Відомо, що такі мережі ефективно використовуються для прогнозування твердості або фазових перетворень на основі складових легування та параметрів, подібних до випробувань за методом Джоміні.

Згорткові нейронні мережі забезпечують автоматичне вилучення інформативних ознак із мікрофотографій без потреби в ручному виділенні меж зерен або фаз. Повністю згорткова мережа (FCNN) для класифікації мікроструктурних компонентів низьковуглецевої сталі досягає точності 93.9 %, що суттєво перевищує результат класичних алгоритмів (~48.9 %).

Для підвищення ефективності моделей за умов обмеженої кількості розмічених даних доцільно використовувати перенавчання (transfer learning) із базових моделей, попередньо натренованих на великих наборах зображень.

У складніших випадках застосовуються гібридні моделі, які поєднують вхідні числові параметри (оброблювані MLP) та візуальні ознаки (отримані з CNN).

Таблиця 1.1 – Варіанти нейронних мереж для прогнозування мікроструктури

Тип моделі	Вхідні дані	Приклад використання	Переваги	Недоліки
MLP (повнозв'язна)	Хімічний склад, параметри термообробки	Прогноз фазового складу або типу мікроструктури	Проста реалізація; ефективність на невеликих вибірках	Обмежена здатність відобразити просторові закономірності
CNN (на основі зображень)	Мікрофотографії мікроструктури	Класифікація: ферит, перліт, мартенсит тощо	Автоматичне вилучення ознак; висока точність	Потребує великих наборів анованих зображень; високе навантаження на обчислення
Гібридна CNN+MLP	Зображення + числові метадані	Прогноз мікроструктури з урахуванням зображення та складу	Інтеграція всіх доступних типів даних; гнучкість	Необхідна синхронізація даних; складність реалізації архітектури

Мікроструктура сталі безпосередньо впливає на її механічні властивості, включаючи межу текучості, твердість та в'язкість. Традиційний металургійний

аналіз спирається на оптичну мікроскопію, скануючу електронну мікроскопію (SEM) та рентгенівську дифракцію (XRD) для ідентифікації фаз. Однак ручна класифікація мікроструктур є суб'єктивною та трудомісткою. Нещодавні досягнення в згорткових нейронних мережах (ЗНМ) дозволили автоматизоване розпізнавання мікроструктур, зменшивши людські помилки та підвищивши точність класифікації.

Однак більшість підходів, заснованих на глибокому навчанні, розглядають класифікацію мікроструктур як суто завдання, засноване на зображеннях, ігноруючи основні закони фізичних перетворень, які керують формуванням фаз. Це дослідження усуває це обмеження шляхом інтеграції фундаментальних металургійних рівнянь у модель нейронної мережі на основі Python для підвищення точності прогнозування та отримання кількісних параметрів мікроструктури.

Успіх моделей нейронних мереж значною мірою залежить від якості та кількості навчальних даних. Набір даних про мікроструктуру сталі з анотаціями Aachen-Heerlen надає повну колекцію зображень скануючої електронної мікроскопії з експертними анотаціями, що сприяє розробці надійних моделей. Правильна підготовка набору даних включає нормалізацію зображень, доповнення та розділення на навчальні, валідаційні та тестові набори для забезпечення узагальнення моделі.

Python, з його великими бібліотеками, такими як TensorFlow та Keras, пропонує універсальну платформу для розробки моделей нейронних мереж. Практичний посібник продемонстрував побудову CNN для класифікації мікроструктур надвисоковуглецевої сталі, досягаючи високої точності завдяки ретельному проектуванню та навчанню моделі. Ключові кроки включають визначення архітектури CNN, компіляцію моделі з відповідними функціями втрат та оптимізаторами, а також навчання моделі на попередньо оброблених даних зображення.

Прогнозування мікроструктури сталі за допомогою машинного навчання, зокрема нейронних мереж, вимагає поєднання металургійних знань та обчислювальних методів. Математичний опис проблеми включає п'ять

основних рівнянь, що регулюють перетворення та класифікацію фаз сталі. Еволюція розпізнавання CNN (рис. 1.3) підпорядковується багатозаровій фільтрації структури зображення та слідує логічній регресії за допомогою математичного опису.

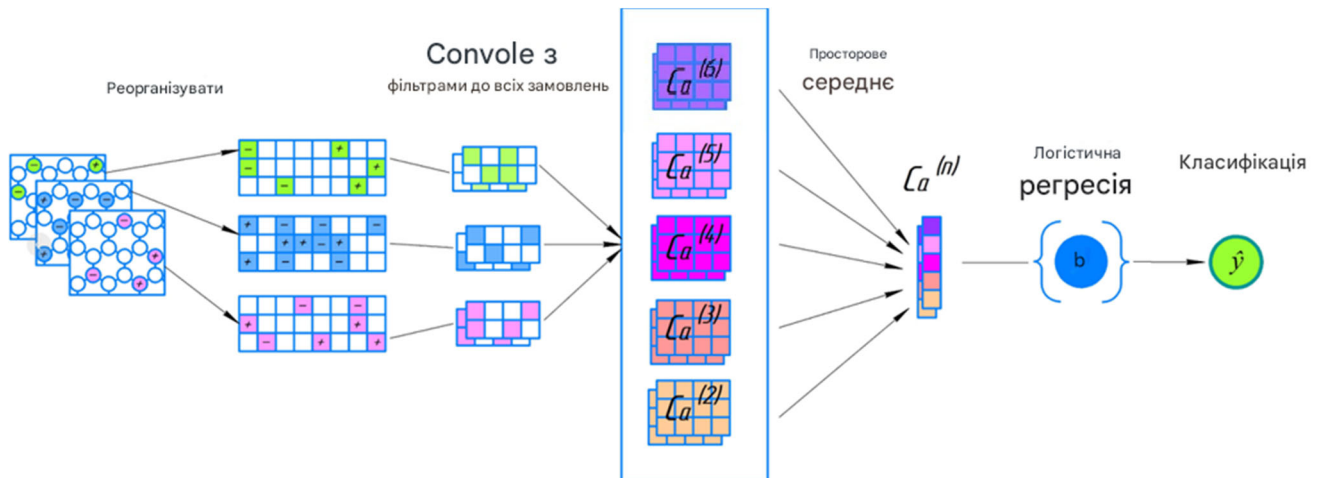


Рисунок 1.3 – Розпізнавання зображень мікроструктури матеріалів за допомогою алгоритму CNN

Кожен тип мікроструктури (наприклад, перліт, мартенсит, бейніт) пов'язаний з фізичними та хімічними дескрипторами, такими як швидкість охолодження R , розмір зерна аустеніту d_γ та вміст вуглецю C . Вектор ознак можна виразити як:

$$X = \{R, d_\gamma, C, T, t, Mn, Cr, Ni, Mo, \dots\}$$

де R – швидкість охолодження, d_γ – розмір зерна попереднього аустеніту, C – вміст вуглецю, T – температура перетворення, t – час витримки при певній температурі, Mn, Cr, Ni, Mo, Mn, Cr, Ni – легуючі елементи, що впливають на фазову стабільність.

Кожен зразок сталі може бути відображений у вектор ознак X_i для навчання нейронної мережі.

Утворення мартенситу залежить від швидкості охолодження та зниження температури нижче температури початку мартенситу M_s . Частка утвореного мартенситу, f_m , визначається рівнянням Койстінена-Марбургера:

$$f_m = 1 - \exp(-\beta(M_s - T))$$

де β – емпірична константа (зазвичай 0,011 для сталі), M_s – температура початку мартенситного формування, T – температура гартування.

Це рівняння служить вхідним перетворенням для моделей машинного навчання.

Стандартна нейронна мережа прямого зв'язку прогнозує фази мікроструктури, використовуючи зважені перетворення та функції активації. Перетворення прихованого шару задається формулою:

$$h_j = \sigma \left(\sum_{i=1}^n \omega_{ji} X_i + b_j \right)$$

де h_j – активація j -го прихованого нейрона, X_i – вхідні характеристики (швидкість охолодження, легуючі елементи тощо), w_{ji} – параметри ваг, що вивчаються, b_j – член зміщення, $\sigma(x) = 1/(1+e^{(-x)})$ – сигмоподібна функція активації.

Остаточна класифікація мікроструктури сталі (ферит, перліт, бейніт, мартенсит) отримується шляхом застосування функції softmax:

$$R_k = \frac{e^{h_k}}{\sum_j e^{h_j}}$$

де P_k – ймовірність належності зразка сталі до фази k .

Мікроструктура впливає на твердість і межу текучості. Рівняння Холла-Петча описує межу текучості σ у залежності від розміру зерна:

$$\sigma_y = \sigma_0 + kd^{-0.5}$$

де σ_0 – власна межа текучості матеріалу, k – коефіцієнт Холла-Петча, d – розмір зерна.

Нейронна мережа може враховувати прогнозовані розміри зерен для оцінки механічних властивостей під час навчання епох, проте таке прогнозування

вимагає достатніх емпіричних досліджень та оптимізації моделі. Для перетворення фериту та перліту під час повільного охолодження, перетворена фракція моделюється за допомогою:

$$f_{\alpha} = 1 - \exp(-kt^n)$$

де f_{α} – частка фази фериту/перліту, k – константа Аврамі, t – час перетворення, n – показник Аврамі, що залежить від механізмів зародження та росту.

Рівняння Аврамі є важливим для фазових перетворень, що залежать від часу, та служить вхідними даними для прогнозування мікроструктури. Це рівняння уточнює класифікацію перліту за CNN, включаючи кінетику перетворення, що залежить від часу.

1.6 Доступність даних та підготовка вхідних ознак

Одним із критичних факторів успішного навчання моделей глибокого навчання для задач мікроструктурного аналізу сталі є наявність якісних та репрезентативних даних. Доступ до великих, структурованих та анотованих наборів мікроструктурних зображень зі супровідними метаданими дозволяє здійснювати навчання, валідацію та тестування з високим рівнем узагальненості результатів.

На сьогодні доступні кілька публічних ресурсів, що містять релевантні дані. Наприклад, набір мікрофотографій ультрависоковоуглецевої сталі від NIST включає 1705 зображень із супровідною інформацією про режими термічної обробки. Набір охоплює широкий спектр термообробок, що дозволяє формувати зв'язки між параметрами процесу та результатною мікроструктурою.

Іншим прикладом є набір SEM-зображень низьколегованої сталі з ручною анотацією типу мікроструктури (мартенсит, перліт, бейніт), доступний через

платформу Mendeleey Data. Ці зображення, доповнені масками сегментації, придатні для навчання моделей згорткової класифікації.

Експериментальні бази даних сталей із 9 % Cr поєднують інформацію про хімічний склад, мікроструктуру та механічні властивості. Незважаючи на орієнтацію таких баз переважно на прогнозування властивостей, їх можна ефективно використати для навчання моделей, що встановлюють причинно-наслідкові зв'язки між складом, обробкою та структурою матеріалу.

У випадках, коли реальні зображення недоступні, актуальним є генерування синтетичних даних - зокрема, за допомогою фазово-польових моделей або інструментів CALPHAD, що дозволяють моделювати процеси утворення мікроструктур у віртуальному середовищі.

Коректна підготовка вхідних ознак є необхідною умовою стабільного й ефективного навчання моделей. Для числових параметрів (відсотковий вміст елементів, температури, швидкості охолодження тощо) застосовується стандартизація - приведення кожної ознаки до нульового середнього значення і одиничного стандартного відхилення. Це забезпечує збалансований внесок кожного параметра до функції втрат і підвищує стійкість оптимізації. Категоріальні змінні, такі як тип термообробки, кодуються у форматі one-hot.

Під час обробки мікроструктурних зображень доцільно здійснювати уніфікацію їхнього розміру, перетворення до відтінків сірого (якщо колірна інформація не несе значимого фізичного навантаження), покращення контрасту та зменшення шумів (наприклад, за допомогою фільтру Гауса). Особливо актуальним є застосування методів аугментації даних: обертання, дзеркальне відображення, зміна яскравості тощо. Такі трансформації підвищують варіативність даних і знижують ризик перенавчання, особливо для CNN-моделей, які чутливі до орієнтацій та особливостей протравлення зразків.

Кожне зображення повинно бути асоційоване з достовірною міткою - фазовим складом або категорією мікроструктури, - що визначається за результатами експериментальних досліджень або анотацією фахівця-металурга.

1.7 Навчання та валідація моделей прогнозування мікроструктури

Процес навчання моделей прогнозування мікроструктури сталі базується на застосуванні перевірених практик машинного навчання, орієнтованих на забезпечення узагальнюваності, стабільності та достовірності результатів. Центральне значення мають методики підготовки навчальних та валідаційних вибірок, вибір метрик якості, застосування регуляризації та інтерпретація поведінки моделі з точки зору фізичної відповідності результатів металургійним закономірностям.

Для уникнення ефекту перенавчання моделі слід попередньо поділити наявні дані на тренувальну, валідаційну та тестову підмножини. Такий розподіл дозволяє об'єктивно оцінити здатність моделі узагальнювати закономірності на нові, раніше не бачені приклади. У випадках обмеженої кількості зразків застосовується перехресна валідація (k-fold cross-validation), що забезпечує ротацію даних між тренувальними та валідаційними частинами для підвищення статистичної достовірності оцінки якості.

Під час навчання моделі важливо відстежувати функцію втрат на валідаційному наборі та застосовувати раннє зупинення (early stopping), що дозволяє припинити навчання на етапі до початку деградації якості моделі.

Для задач класифікації мікроструктури існують такі базові метрики як, accuracy (загальна точність), precision/recall/F1-score (особливо важливо при нерівномірному розподілі класів) та матриця змішування (confusion matrix), що дозволяє оцінити характер помилок класифікації.

Водночас, моделі мають бути вивірені металургійно - тобто передбачена структура має бути фізично правдоподібною в контексті вхідних параметрів (наприклад, низьковуглецева сталь, охолоджена повільно, не повинна бути класифікована як мартенситна). Таку експертну перевірку варто проводити як додаткову якісну валідацію.

У випадках, коли цільовою змінною є неперервна величина (наприклад, середній розмір зерна або об'ємна частка фази), модель формулюється як

регресійна нейронна мережа, а якість прогнозу оцінюється за допомогою середньоквадратичної помилки (MSE) та коефіцієнта кореляції (R^2) між передбаченням і вимірними значеннями.

Для вивчення поведінки CNN-моделей і підтвердження того, що модель орієнтується на фізично релевантні ознаки (наприклад, межі зерен, зональність фаз), застосовуються методи візуалізації вхідних ознак, які активують конкретні фільтри згорткових шарів. Одним із найбільш інформативних підходів є карти важливості (saliency maps), що відображають пікселі з найбільшим впливом на рішення моделі. Це дозволяє переконатися, що модель навчається на структурних елементах мікроструктури, а не на артефактах зображення або фоновому шумі.

Для прискорення процесу навчання нейронних мереж, особливо при використанні великих зображень та складних моделей (ResNet, U-Net, DeepLabv3+), доцільно використовувати графічні процесори (GPU). Бібліотеки TensorFlow та PyTorch забезпечують апаратне прискорення через CUDA/OpenCL та підтримують гнучке конфігурування обчислювального середовища. Важливо інтегрувати ці ресурси у навчальне середовище інструменту, що розробляється, аби мінімізувати час моделювання та забезпечити масштабованість на більші обсяги даних.

1.8 Постановка задач дослідження

На основі проведеного аналізу механізму утворення неметалевих включень та формування структури сталей, поставлено задачу із розробки алгоритму автоматизованого розпізнавання зображення мікрознімку сталі із подальшим отриманням результату аналізу – мікроструктури матеріалу та потенційними зонами неметалевих включень. Для вирішення задачі необхідно створити математичну модель для аналізу зображень та використовуючи знання із матеріалознавства виконати навчання моделі на еталонних зображеннях.

2 ФУНКЦІОНАЛЬНИЙ АНАЛІЗ ТА МОДЕЛЮВАННЯ ОБ'ЄКТА РОЗРОБКИ

2.1 Визначення методики математичного опису зображень мікроструктури сталі та функціонально-вартісний аналіз розробки

Функціонально–вартісний аналіз (ФВА) є одним із найпотужніших інструментів комплексного оцінювання продукції, що дозволяє зв'язати технічні характеристики виробу з його повною собівартістю, включно з непрямими, експлуатаційними та екологічними витратами. Головна мета ФВА полягає у визначенні тих елементів конструкції чи технологічного процесу, які генерують найбільшу цінність для кінцевого користувача за мінімальних витрат ресурсів. Водночас методика виявляє вузькі місця, де співвідношення «переваги / затрати» є найменш вигідним, і надає обґрунтування для їх вдосконалення або скорочення непотрібних витрат.

Сутність ФВА полягає у послідовному виконанні кількох етапів. Спочатку необхідно чітко структурувати складові виробу або процесу й виділити їхні базові функції. На цьому етапі формується «функціональна модель», у якій кожному елементу присвоюється одна або кілька функцій залежно від його призначення. Далі для кожної функції здійснюється кількісна оцінка витрат, включаючи як прямі виробничі (матеріальні, трудові, енергетичні), так і приховані експлуатаційні (технічне обслуговування, утилізація) та екологічні складові. Паралельно з оцінюванням витрат визначається цінність функції — тобто ступінь впливу на технічну придатність, надійність, безпеку й конкурентоспроможність виробу. На завершальному етапі виконується зіставлення витрат із цінністю (Cost–Value Matrix) і виявлення пріоритетних напрямів вдосконалення.

На практиці ФВА широко застосовується у машинобудуванні, автомобільній та авіаційній промисловості, в енергетиці й будівництві. Завдяки йому дизайнери та інженери можуть обґрунтувати рішення про вибір

матеріалів із оптимальним поєднанням вартості та експлуатаційних характеристик, спрощувати конструкцію без шкоди для безпеки, переглядати технологічні операції задля скорочення часу виробництва та енергоспоживання. В умовах жорсткої конкуренції на ринку наявність чіткого ФВА дає змогу компаніям формувати ціннісні пропозиції, підтвержені кількісними розрахунками, і ефективно впроваджувати інновації, мінімізуючи ризики перевитрат.

Таким чином, функціонально–вартісний аналіз є стратегічним механізмом підвищення ефективності виробничих процесів і конкурентоспроможності продукції. Він створює основу для системного підходу до оптимізації й одночасної гарантії необхідного рівня якості та надійності, що в сучасних умовах є критичним чинником успіху будь-якого інженерного проєкту.

Розмір зерен є фундаментальною характеристикою мікроструктури сталі, що безпосередньо впливає на механічні властивості, зокрема міцність і ударну в'язкість. У промисловій практиці розмір зерна зазвичай подається як середній діаметр або у вигляді номера зерна ASTM. Традиційні методи вимірювання ґрунтуються на ручному підрахунку зерен або перетинів меж зерен під мікроскопом згідно зі стандартом ASTM E112, однак такі методи є трудомісткими та суб'єктивними. З огляду на це, виникає потреба в створенні автоматизованих інструментів аналізу зображень, що поєднують класичні алгоритми комп'ютерного зору, ML-моделі й бібліотеки Python.

У практиці виділяють два основні підходи до вимірювання розміру зерен, а саме, метод перетинів (метод Гейна) - базується на підрахунку кількості перетинів зерен через накладені лінії, та планіметричний метод - передбачає сегментацію індивідуальних зерен і подальший розрахунок площ разом із еквівалентними діаметрами.

2.2 Аналіз архітектури моделей розпізнавання зображень за функціональним змістом

Залежно від рівня деталізації задачі можна виокремити три підходи: Детекція об'єктів: локалізація включень у вигляді прямокутників (bounding boxes) за допомогою моделей типу YOLOv5, Faster R-CNN; семантична або інстанс-сегментація: побудова точних піксельних масок включень з можливістю класифікації (моделі U-Net, Mask R-CNN, DeepLabv3+); класифікація окремих фрагментів (patch-based CNN): після попереднього виявлення фрагментів включень вони подаються на вхід моделі для класифікації типу (оксид, сульфід тощо).

Таблиця 2.1 – Функціональне призначення модулів застосунку

ID	Компонент-модуль	Функція
D1	Інтерфейс завантаження даних	F1: Зчитує мікрографії та/або табличні дані.
D2	Пре-процесинг зображень	F2: Фільтрація, нормалізація, корекція освітлення.
D3	Сегментація зерен	F3: Порогова бінаризація, детектування країв, watershed.
D4	Обчислювач метрік	F4: Підрахунок перетинів, площа, еквівалентний діаметр.
D5	Нейронний модуль	F5: МЛ-прогноз (розпізнавання фаз/оцінка розміру).
D6	Візуалізація та звітність	F6: Побудова графіків, збереження звітів у PDF/Excel.
D7	Конфігурація та логування	F7: Зчитування параметрів запуску, ведення логів.
D8	Тестовий каркас	F8: Юніт-тести, перевірка коректності модулів.

Таблиця 2.2 - Підходи до виявлення неметалевих включень

Підхід	Приклад моделей	Вихідні дані	Переваги	Недоліки
Детекція об'єктів	YOLOv5, Faster R-CNN	Bounding box навколо включення	Висока швидкість роботи; проста розмітка	Нечіткі межі включень; не підходить для

Підхід	Приклад моделей	Вихідні дані	Переваги	Недоліки
				вимірювання площі
Семантична сегментація	DeepLabv3+, U-Net	Піксельна маска включення	Точна морфологія; можливість обчислення площі	Потребує точного піксельного маркування; обчислювально складна
Інстанс-сегментація	Mask R-CNN	Маска + клас кожного включення	Розрізнення перекриваних об'єктів; типова класифікація	Складність архітектури; потреба в великій кількості розмічених прикладів
Класифікація (патчі)	CNN (ResNet тощо)	Тип включення за окремим фрагментом	Простота моделі; застосовується як другий етап після детекції	Не здійснює локалізацію; вимагає окремого етапу для виділення включень

Таблиця 2.2 – Функціонально-вартісний аналіз функцій та модулів застосунку

Модуль (D)	Функція (F)	Вартість (CAPEX+OPEX)	Надійність / Довговічність	Технічна значущість / Генерована цінність
D1	F1	Середня (розробка парсерів, підтримка форматів)	Висока (проверена I/O)	Критична – без даних немає аналізу
D2	F2	Середня (підбір фільтрів, налаштування параметрів)	Середня (залежить від різноманіття зображень)	Висока – підготовка даних впливає на точність всіх подальших кроків

Модуль (D)	Функція (F)	Вартість (CAPEX+OPEX)	Надійність / Довговічність	Технічна значущість / Генерована цінність
D3	F3	Висока (складний код сегментації, edge-кейси)	Середня (чутливість до якості)	Висока – базова стадія обчислень grain size / inclusion
D4	F4	Низька (алгоритми regionprops, basic loops)	Висока	Середня – дає кількісні результати grain size
D5	F5	Висока (тренування/тонке налаштування моделі, GPU-інфраструктура)	Висока (при правильному навчанні)	Ключова – дає більш гнучкі/точні прогнози мікроструктури
D6	F6	Низька (Matplotlib, pandas, експортування)	Висока	Середня – представлення результатів користувачу
D7	F7	Низька (argparse, logging)	Висока	Середня – дебаг та автоматизація
D8	F8	Середня (написання тестів, CI/CD)	Висока	Висока – гарантія коректності при змінах

ФВА показав, що найбільшу цінність при високій витраті містять модулі нейронної інференції та сегментації, але їх можна здешевити через оптимізацію моделей і алгоритмів. Інвестиції в тестування й автоматичний препроцесинг значно підвищують надійність і довговічність рішення, а покращення GUI/CLI та звітності збільшують комфорт і швидкість прийняття рішень користувачем.

2.3 Визначення методики попередньої обробки зображень

Ключовою передумовою якісного аналізу є забезпечення чіткого зображення з добре візуалізованими межами зерен, що зазвичай досягається шляхом оптимального травлення поверхні зразка. Алгоритм попередньої

обробки включає в себе приглушення шуму (наприклад, згладжуванням за Гаусом), покращення контрасту (методи гістограмного вирівнювання), порогову обробку - застосування методу Оцу або адаптивного порогоування для виділення меж зерен, виділення країв - із використанням фільтрів Собеля, Кенні або Лапласа (OpenCV).

У результаті формується бінаризоване зображення, де зерна і межі чітко розділені. Подальші етапи залежать від обраного методу аналізу.

2.4 Математичне описання процесу аналізу зображення

Розпізнавання об'єктів мікроструктури на багатоспектральних зображеннях обчислювальним методом лінійної регресії з використанням середньоквадратичної похибки на етапі попередньої обробки стає більш точним:

$$\frac{1}{N} \sum_{i=1}^N |\gamma_i - \mu|$$

де γ_i - мітка для екземпляра; N - номер екземпляра; μ - середнє значення, що задається.

Компіляція інформації використовується для поділу даних за допомогою ентропії та обчислюється як зменшення ентропії після поділу набору даних на атрибути:

$$\text{Компіляція}(T, X) = \text{Ентропія}(T) - \text{Ентропія}(T, X),$$

де T – цільова змінна; X – класифікаційна характеристика; $\text{Ентропія}(T, X)$ – ентропія, обчислена після поділу даних на ознаку X

Для кожного дерева рішень обчислюють значення вузлів, припускаючи лише два дочірні вузли (двійкове дерево):

$$ni_j = w_j C_j - W_{left(j)} C_{left(j)} - W_{right(j)} C_{right(j)}$$

де ni_j – значення вузла j ; W_j - зважена кількість зразків, що досягають вузла j ; C_j – кількість домішок у вузлі; $left(j)$ та $right(j)$ – дочірні вузли, розділені зліва і справа на вузлі j .

Значення кожного елемента дерева рішень обчислюється як:

$$fi_i = \frac{\sum_j ni_j}{\sum_k ni_k}$$

де fi_i – значущість за ознакою i ; ni_j - значущість за вузлом j .

Зазначенні значення підлягають нормалізації до значення між нулем і одиницею. Поділивши їх на суму всіх значень ознаки за значущістю, отримаємо:

$$norm\ fi_i = \frac{fi_i}{\sum_i fi_i}$$

Вихідна ознака за значущістю - це середнє значення всіх дерев рішень. Сума значень ознак за значущістю на кожному дереві обчислюється і ділиться на загальну кількість дерев:

$$RF\ fi_i = \frac{\sum_j norm\ fi_{ij}}{T}$$

де $RF\ fi_i$ - значущість ознаки i , обчислена з усіх дерев рішень у моделі; $norm\ fi_{ij}$ - нормалізована значущість ознаки для i в дереві j ; T - загальна кількість дерев.

2.5 Автоматизована реалізація методу перетинів

В основі методу лежить накладання сітки прямих ліній на зображення з наступним підрахунком кількості перетинів меж зерен кожною лінією. Середня довжина між перетинами використовується для розрахунку середнього розміру зерен або номера за ASTM.

Автоматизована реалізація передбачає: накладання регулярної сітки з горизонтальних та вертикальних ліній (OpenCV: `cv2.line`); сканування кожної лінії на предмет зміни піксельної інтенсивності; використання алгоритмів скелетизації (наприклад, `skimage.morphology.skeletonize`) для зведення меж зерен до товщини в 1 піксель; побудову графової моделі меж зерен і підрахунок кількості перетинів.

Один з ефективних підходів описаний у роботі [3], де застосовується топологічний скелет для автоматичного визначення точок перетину відповідно до вимог ASTM E112. Така реалізація враховує складні випадки, включно з потрійними точками, які мають вагу 0.5 при підрахунку.

Після обробки отримані довжини перетинів конвертуються у середній діаметр зерна або номер ASTM за відповідними аналітичними залежностями.

2.6 Інтеграція планіметричного методу сегментації зерен

Планіметричний підхід ґрунтується на повній сегментації окремих зерен на зображенні. Одним із найбільш надійних методів є алгоритм водорозділу (`watershed segmentation`), який включає в себе наступні дії: Створюється інверсне зображення зерен (тобто зерна - яскраві області); застосовується `distance transform` до бінарного зображення; використовується алгоритм `skimage.segmentation.watershed` для поділу дотичних зерен.

Після сегментації функція `regionprops` дозволяє обчислити площу кожного зерна та отримати еквівалентні кругові діаметри. Додатково може бути реалізована фільтрація за розміром для виключення артефактів та неповних зерен на краях зображення.

Надмірна або недостатня сегментація усувається шляхом тонкого налаштування параметрів фільтрації й попередньої обробки, а також візуальною верифікацією - накладанням контурів сегментованих зерен на оригінальне зображення.

2.7 Технологічна реалізація

Бібліотеки OpenCV (`cv2.threshold`, `cv2.findContours`, `cv2.drawContours`) та scikit-image (`threshold_otsu`, `sobel`, `label`, `regionprops`) забезпечують повний інструментарій для реалізації зазначених методів. Створено також значну кількість спільнотних скриптів (ImageJ macro, Python на GitHub), що підтверджує інтерес до автоматизації цього аспекту металографії.

У роботі представлено відкриті набори з мікроструктурами ультрависоковоуглецевої сталі, що слугують стандартом для тестування алгоритмів оцінки розміру зерна.

Результати аналізу доцільно подати у вигляді наступних параметрів: середнього діаметра зерна, розподілу за розмірами (гістограма) та візуалізації накладення контурів зерен.

Для побудови графіків застосовуються Matplotlib або Seaborn. Розподіл розміру зерен у металах зазвичай наближається до нормального логарифмічного закону, тому додатковий аналіз форми розподілу може бути використаний для глибшої інтерпретації мікроструктури.

2.8 Висновки за розділом

У розділі запропоновано комплексну методику автоматизованого аналізу зображень мікроструктури сталі, яка поєднує етапи попередньої обробки, сегментації та кількісної оцінки розміру зерен. Рекомендовано застосовувати фільтрацію та корекцію освітлення задля уніфікації контрасту, після чого використовують класичні алгоритми бінаризації та методу водорозділу, а також сучасні нейромережеві моделі для виділення індивідуальних зерен чи неметалевих включень.

Для обчислення середнього діаметра зерна втілено два підходи: інтерцепційний метод зі стягуванням лінійних перетинів зернових меж та планіметричний метод із повною сегментацією і розрахунком площ зерен із перетворенням у еквівалентні діаметри за стандартом ASTM.

Проведено функціонально-вартісний аналіз архітектури Python-застосунку, виділивши ключові модулі від завантаження даних до побудови звітів і тестування. Виявлено, що сегментація та нейронний модуль формують основну частину витрат на розробку й обчислювальні ресурси, проте забезпечують найвищу цінність завдяки точності результатів. Інвестиції у оптимізацію інференсу, поліпшення препроцесингу та розширення юніт-тестів дозволять підвищити надійність і знизити вартість подальшого експлуатаційного обслуговування, забезпечивши збалансоване співвідношення «витрати–користь» для кінцевого користувача.

3 ІНЖЕНЕРНО-ТЕХНОЛОГІЧНИЙ РОЗДІЛ

3.1 Аналіз впливу термічних напружень поблизу включень

Відмінність у фізичних, механічних і хімічних властивостях включення та матриці сталі призводить до виникнення напружень на межі їх розділу, величина яких залежить від низки чинників: когерентності включення і матриці, яка визначається ступенем відповідності їхніх кристалічних структур та енергією поверхні розділу. За відсутності зовнішнього впливу у сталі виникають залишкові напруження, зумовлені наявністю включень. Ці напруження спричинені міжфазними напруженнями на межах розділу включення-матриця, фазовим наклепом, пов'язаним з перетвореннями у сталі й у частинках при зміні температури, а також концентрацією дефектів кристалічної будови. Поблизу поверхні частинки їхня величина становить порядку $GM/100$, де GM — модуль зсуву матриці [16]. Прикладення зовнішнього навантаження також спричиняє додаткові напруження поблизу частинок через різницю в пружних сталих матриці та включень. Ці напруження можуть бути нормальними (розтягувальними або стискальними) та зсувними і мають локальний характер.

У процесі охолодження сталі термічні напруження безперервно зростають до певного рівня (критичного значення, що дорівнює межі плинності матриці), після чого відбувається їх релаксація шляхом пластичних зсувів або ротацій у ділянці, прилеглій до включення. Перша релаксація має лавиноподібний характер. Якщо охолодження сталі продовжується, термічні напруження знову зростають і настає нова, друга релаксація і так далі. За наявності кількох циклів зниження напружень релаксація має східчастий або хвильовий характер. Релаксація може відбуватися безпосередньо від міжфазної межі включення-матриця або на деякій відстані від неї.




Рисунок 3.1 – Мікроструктура матриці сталі ЕЗ (а - г, е) та 08Ю (д) поблизу включень: а - г, - х600; д, е - х20000

Характер розподілу дислокацій свідчить про їх розташування у певних кристалографічних площинах і напрямках (рис. 3.1, а). Хвильова релаксація, як правило, пов'язана з зародженням і дією дислокаційних джерел на міжфазній межі, наприклад, джерел Бардіна-Геррінга. Кожна дислокаційна петля під час свого руху створює хвилю зсуву. Оскільки виникнення термічних напружень пов'язане з охолодженням сталі з досить високої температури, в релаксаційних процесах велику роль відіграють точкові дефекти, що знаходяться на міжфазних межах. Можливе утворення нерівноважних конфігурацій, таких як структурні вакансії. Підвищена концентрація вакансій сприяє переповзанню дислокацій та появі елементів полігонізації, коли виникають окремі обірвані субмежі (рис. 3.1, б, д, е) або навіть формується «павукоподібна» розгалужена мережа субмеж (рис. 1.4, в). Наявність поблизу включень обмежених внутрішніх поверхонь розділу є еквівалентною наявності часткових дислокацій (рис. 3.1, в, г). Місця обриву субмеж є ділянками, де неминуче відбувається поворот кристалічної ґратки

для збереження неперервності зерна. Включення в результаті опиняються в полях моментних напружень.

3.2 Вплив неметалевих включень на механізми деформації та руйнування сталей при різних температурах

Неметалеві включення справляють суттєвий вплив на структуру зламу при в'язкому транскристалітному руйнуванні та руйнуванні змішаного типу (квазив'язкому та квазікрихкому), викликаючи утворення великих лунок на поверхні, що призводить до неоднорідної структури зламів. Коли в'язке інтеркристалітне руйнування відбувається по межах зерен, які утворилися внаслідок збиральної рекристалізації, внутрішньозернові включення не впливають на структуру зламу; лише включення, що знаходяться на межах зерен, впливають на руйнування сталі. У разі крихкого транскристалітного руйнування, включення не впливають на структуру зламу. Включення є найбільш небезпечними з точки зору впливу на руйнування у випадку, коли деформація сталі відбувається шляхом внутрішньозеренного ковзання, а руйнування розвивається за механізмом в'язкого транскристалітного або змішаного типу руйнування.

Пластичні властивості сталі за будь-якої температури деформації значною мірою визначаються міцністю межі включення–матриця, яка залежить від механічної та хімічної взаємодії включень і матриці, відповідності їх кристалічних ґраток та змочуваності включень рідкою сталлю. Порожнини утворюються біля включень корунду, шпінелей, оксидів, що не деформуються, розміри яких перевищують критичні значення, які залежать від температури й типу включення і знаходяться в межах 6...23 мкм. Ступінь деформації, при якому зароджуються порожнини поблизу включень, зростає, а інтервал деформацій, у якому включення контролюють руйнування сталі, тобто є єдиним джерелом руйнування, зменшується зі збільшенням температури. Швидкість росту порожнин і їхній розмір у включень однакового діаметра при підвищенні температури зменшуються, що призводить до зниження загальної

протяжності мікроруйнувань у сталі. Підвищення температури деформації зменшує шкідливий вплив внутрішньозеренних включень на руйнування, і при 1000...1200 °С, коли відбувається в'язке інтеркристалітне руйнування сталі, зводить його до мінімуму. У цьому випадку небезпеку становлять включення, розташовані на межах зерен. При крихкому транскристалітному руйнуванні всі внутрішньозеренні включення беруть участь у руйнуванні.

До легкоплавких включень належать сульфіди, а також сульфідні та оксисульфідні евтектики, які нерідко є причиною червоноламкості сталей.

Сульфідна червоноламкість сталі. Склад і структура евтектичних сульфідних включень у сталях 08кп, 08Х, 60Г, НБ-57, ШХ15, АЦ45Х, АЦ18ХГТ досліджувались металографічними та мікрорентгеноспектральними методами, а також шляхом проведення петрографічного аналізу частинок, вилучених з поверхні шліфа. У сталі 08кп виявлено оксисульфідні евтектичні включення FeS–FeO. У сталях НБ-57, 60Г, АЦ18ХГТ досліджено два типи евтектик: сульфідна (Fe,Mn)S–FeS та оксисульфідна (Fe,Mn)S–FeO. У сталях 08Х та АЦ45Х легкоплавкими евтектиками є сульфідна (Fe,Mn,Cr)S–FeS та оксисульфідна (Fe,Mn,Cr)S–FeO. У сталях ШХ15 виявлено три типи евтектичних включень: сульфідні (Fe,Cr,Mn)S–(Fe,Mn)S, оксисульфідні (Fe,Cr,Mn)S–FeO та евтектика сульфід–матриця сталі, яка зазвичай оточує включення двох перших типів.

Зразки досліджуваних сталей піддавались розтягуванню у вакуумі при температурах 25...1250 °С зі швидкістю деформації 1680 мм/год. Досліджувався характер мікроруйнувань поблизу пластичних сульфідів за різних температур.

За всіх температур у матриці досліджуваних сталей поблизу евтектичних включень і в самих включеннях спостерігалася локалізація деформації. Механізми розвитку деформації та утворення мікроруйнувань залежать від співвідношення пластичності включень і матриці, а також від температури. Якщо включення й матриця є пластичними за низьких температур, дислокації виходять на межу їх розділу як з боку матриці, так і з боку включення.

Оксисульфідна евтектика FeS–FeO є пластичною в інтервалі температур 25...900 °С. При підвищенні температури до 980 °С евтектика починає розплавлятися спочатку на межі розділу з матрицею, а потім у процесі розвитку деформації включення повністю розплавляються. Розплавлення включень викликає локалізацію деформації у прилеглих ділянках матриці (рис. 2.20, а), що, у свою чергу, стимулює ріст порожнин.




Рисунок 3.2 – Включення евтектичних сульфідів у сталях 08кп (а), 08Х (б), НБ-57 (в – д) після деформації за температур 25 (б), 900 (в), 1000 (а), 1100 (г) і 1200 °С (д), × 500

Частинки хромовмісних сульфідних і оксисульфідних евтектик менш пластичні, ніж евтектика FeS–FeO у сталі 08кп, і при температурах 25–500 °С руйнуються крихко внаслідок локалізації деформації в матриці (рис. 2.20, б). При підвищенні температури до 600 °С і вище (до 1100 °С) пластичність включень зростає, вони деформуються разом із пластичною матрицею. Внаслідок локалізації деформації можливе порушення суцільності вздовж меж розділу та утворення порожнин. Для інтервалу температур 600...1250 °С характерне розшарування вздовж меж розділу та утворення порожнин (рис.

2.20, в). Гострі краї включень у процесі деформації згладжуються (рис. 2.20, г).

Включення сульфідної марганцевої евтектики при 1050 °С, а окисульфідної — при 1120 °С розплавляються, що сприяє інтенсивному росту порожнин. Подальше підвищення температури викликає масове розплавлення евтектичних включень, у сталі з'являються готові порожнини, заповнені розплавом. Поблизу таких порожнин виникає характерний рельєф деформації (рис. 2.20, д), який свідчить про її локалізацію, розвиток фрагментації, що, у свою чергу, сприяє швидкому росту порожнин.

3.3 Постановка інженерної задачі формування моделі

Неметалеві включення (NMI, Non-Metallic Inclusions), як-от оксиди, сульфіди, силікати та алюмінати, є типовими сторонніми фазами в сталі, що істотно впливають на її міцність, пластичність і довговічність. Виявлення та класифікація таких включень становлять важливий елемент контролю якості у металургії. Традиційно аналіз проводиться вручну за допомогою оптичної мікроскопії згідно зі стандартами (наприклад, ASTM E45), однак цей підхід є надзвичайно трудомістким та суб'єктивним.

Ефективне навчання вищенаведених моделей вимагає формування якісного датасету з мікрофотографіями сталі, що містять вручну анотовані включення. Для цього доцільно використовувати наступні два інструменти: LabelImg для анотації bounding boxes; COCO Annotator або CVAT - для створення піксельних масок.

Важливо охопити повну номенклатуру типів включень (оксиди, сульфіди, алюмінати, силікати), а також забезпечити репрезентативність розмірного діапазону. Через нерівномірну присутність включень у зразках (вони є рідкісними об'єктами), доцільним є формування підмножин із локальними фрагментами з одним включенням, що дозволяє зосередити навчання на релевантних регіонах.

За відсутності публічних наборів зображень допускається використання: власних металографічних зйомок; зображень з літератури (з дотриманням прав використання); набору даних CMU (він містить статистику, хоча й не повні зображення).

3.4 Навчання моделей та оцінка точності визначення структури

Для моделей типу YOLO рекомендується використання бібліотек: Ultralytics YOLOv5 (Python) та Detectron2 (розробка Facebook для детекції та сегментації).

Навчання супроводжується метриками: mAP (mean Average Precision) - для детекції; IoU (Intersection over Union) - для сегментації.

Для об'єктивної перевірки узагальнюваності моделі важливо проводити валідацію на зображеннях, отриманих з інших зразків, а не лише зі штучного розподілу датасету. Якщо набір даних невеликий - застосовується перехресна валідація.

Особливу увагу слід приділити дисбалансу класів. Наприклад, у ресульфурованих сталях сульфіди домінують, тоді як оксиди можуть бути представлені поодинокі. У таких випадках рекомендується застосування focal loss або зваженої функції втрат.

Підхід CNN для класифікації зображень (Microstructure Types)

Маючи папку зображень, позначену підпапками (Наприклад, data/ferrite/*.jpg, data/martensite/*.jpg), виконується навчання CNN (наприклад, використовуючи PyTorch's ImageFolder та DataLoader):

Упорядкування даних:

```
data/  
  ferrite/  
    image1.jpg  
    image2.jpg  
    ...  
  martensite/  
    image1.jpg  
    image2.jpg  
    ...
```

Папка зображень PyTorch

```
import torch
from torchvision import datasets, transforms
from torch.utils.data import DataLoader

transform = transforms.Compose([
    transforms.Resize((224, 224)),
    transforms.ToTensor()
])

dataset = datasets.ImageFolder("data", transform=transform)
train_size = int(0.8 * len(dataset))
test_size = len(dataset) - train_size
train_dataset, test_dataset = torch.utils.data.random_split(dataset,
[train_size, test_size])

train_loader = DataLoader(train_dataset, batch_size=16, shuffle=True)
test_loader = DataLoader(test_dataset, batch_size=16, shuffle=False)
```

Визначення мережі

```
import torch.nn as nn
import torch.optim as optim
import torchvision.models as models

# Example: Transfer learning with ResNet18
model = models.resnet18(pretrained=True)
# Adjust final layer to match your # of classes (e.g. 2 = ferrite, martensite)
num_features = model.fc.in_features
model.fc = nn.Linear(num_features, 2)

criterion = nn.CrossEntropyLoss()
optimizer = optim.Adam(model.parameters(), lr=1e-3)
```

Тренувальний цикл:

```
for epoch in range(10): # e.g., 10 epochs
    model.train()
    for images, labels in train_loader:
        optimizer.zero_grad()
        outputs = model(images)
        loss = criterion(outputs, labels)
        loss.backward()
        optimizer.step()
```

```
print(f"Epoch {epoch+1} completed")
```

Перевірка:

```
model.eval()
correct = 0
total = 0
with torch.no_grad():
    for images, labels in test_loader:
        outputs = model(images)
        _, predicted = torch.max(outputs, 1)
        total += labels.size(0)
        correct += (predicted == labels).sum().item()
accuracy = 100 * correct / total
print(f"Test Accuracy: {accuracy:.2f}%")

import cv2
import numpy as np
import matplotlib.pyplot as plt

from skimage import morphology, measure
from skimage.segmentation import watershed
from scipy import ndimage as ndi

def load_image_as_gray(path):
    """
    Loads an image from 'path' as a grayscale NumPy array.
    """
    img = cv2.imread(path, cv2.IMREAD_GRAYSCALE)
    if img is None:
        raise FileNotFoundError(f"Could not load image at {path}")
    return img

def skeletonize_image(gray_img):
    """
    1. Apply Gaussian blur
    2. Apply Otsu threshold
    3. Invert
    4. Skeletonize
    Returns the binary boundary image and skeleton image.
    """
    blur = cv2.GaussianBlur(gray_img, (5, 5), 0)
    _, binary = cv2.threshold(blur, 0, 255, cv2.THRESH_BINARY +
cv2.THRESH_OTSU)

    # Invert so that boundaries become white
```

```

inverted = cv2.bitwise_not(binary)

# Skeletonize
from skimage.morphology import skeletonize
skeleton = skeletonize(inverted // 255)

return inverted, skeleton

def line_intercept_method(skeleton, spacing=50):
    """
    Implements a simplified line intercept approach.
    skeleton: 2D boolean array (True=boundary, False=not boundary).
    spacing: distance (in pixels) between parallel lines.
    Returns the average intercept count per line.
    """
    h, w = skeleton.shape
    intercept_counts = []

    # Horizontal lines
    for y in range(0, h, spacing):
        line = skeleton[y, :]
        # Count transitions from 0->1
        count = np.sum(np.diff(line.astype(int)) == 1)
        intercept_counts.append(count)

    # Vertical lines
    for x in range(0, w, spacing):
        line = skeleton[:, x]
        count = np.sum(np.diff(line.astype(int)) == 1)
        intercept_counts.append(count)

    avg_intercepts = np.mean(intercept_counts) if len(intercept_counts) > 0
else 0
    return avg_intercepts

def planimetric_grain_size(boundary_image):
    """
    Performs a watershed-based segmentation of grains:
    1. Invert boundary image so grain interiors are white
    2. Distance transform
    3. Watershed with local maxima
    4. Compute average area of grains (in pixels)
    Returns:
        - labels (segmentation map)
    """

```

```

    - average grain area (pixels)
    """
    # boundary_image is typically 0/255; invert to get grain interiors = 255
    inverted = cv2.bitwise_not(boundary_image)
    mask = inverted > 0 # True for grain interiors

    # Distance transform
    dist = ndi.distance_transform_edt(mask)

    # Markers for watershed = local maxima
    local_max = morphology.local_maxima(dist)
    markers = measure.label(local_max)

    # Apply watershed
    labels = watershed(-dist, markers, mask=mask)

    # Measure each grain's area
    props = measure.regionprops(labels)
    areas = [p.area for p in props]
    avg_area = np.mean(areas) if areas else 0

    return labels, avg_area

def detect_inclusions(gray_img):
    """
    Basic inclusion detection:
    1. Threshold the grayscale image
    2. Morphological opening to remove noise
    3. Connected components to count and measure inclusion areas
    Returns:
        - inclusion_count
        - average_inclusion_area (in pixels)
        - label image for visualization
    """
    # Threshold (assuming inclusions are darker)
    _, binary = cv2.threshold(gray_img, 80, 255, cv2.THRESH_BINARY_INV)

    # Morphological opening to remove small noise
    kernel = cv2.getStructuringElement(cv2.MORPH_ELLIPSE, (3,3))
    opened = cv2.morphologyEx(binary, cv2.MORPH_OPEN, kernel)

    # Connected components
    num_labels, labels_im = cv2.connectedComponents(opened)

```

```

# Count actual inclusions (excluding background label=0)
inclusion_count = num_labels - 1

# Measure areas
stats = []
for label_val in range(1, num_labels):
    mask = (labels_im == label_val)
    area = np.sum(mask)
    stats.append(area)
avg_inclusion_area = np.mean(stats) if stats else 0

return inclusion_count, avg_inclusion_area, labels_im

def main():
    # -----
    # 1. Load and Skeletonize Image for Grain Analysis
    # -----
    grain_image_path = "grain_sample.jpg" # <-- Replace with your image file
    grain_img = load_image_as_gray(grain_image_path)

    # Skeletonize
    boundary_img, skeleton = skeletonize_image(grain_img)

    # Display the images
    plt.figure(figsize=(12, 4))
    plt.subplot(1,3,1)
    plt.title("Original Image")
    plt.imshow(grain_img, cmap='gray')

    plt.subplot(1,3,2)
    plt.title("Binary Boundary")
    plt.imshow(boundary_img, cmap='gray')

    plt.subplot(1,3,3)
    plt.title("Skeletonized")
    plt.imshow(skeleton, cmap='gray')
    plt.show()

    # -----
    # 2. Grain Size Analysis
    # -----
    # 2a. Line Intercept
    avg_intercepts = line_intercept_method(skeleton, spacing=50)
    print(f"[Line Intercept] Avg intercepts per line: {avg_intercepts:.2f}")

```

```

# If you know the real pixel scale, convert intercepts to micrometers or
mm.

# Then apply standard formulas (ASTM E112) to get average grain diameter
or grain size number.

# 2b. Planimetric (Watershed)
labels, avg_area_pixels = planimetric_grain_size(boundary_img)
print(f"[Planimetric] Number of grains: {labels.max()}")
print(f"[Planimetric]         Average         grain         area         (pixels):
{avg_area_pixels:.2f}")

# Show the labeled grains
plt.figure(figsize=(12, 5))
plt.subplot(1,2,1)
plt.title("Boundary Image")
plt.imshow(boundary_img, cmap='gray')
plt.subplot(1,2,2)
plt.title("Watershed Labeled Grains")
plt.imshow(labels, cmap='nipy_spectral')
plt.show()

# -----
# 3. Inclusion Detection
# -----
inclusion_image_path = "inclusion_sample.jpg" # <-- Replace with your
image file
inclusion_img = load_image_as_gray(inclusion_image_path)

inclusion_count,         avg_inclusion_area,         labels_im         =
detect_inclusions(inclusion_img)
print(f"[Inclusions] Detected count: {inclusion_count}")
print(f"[Inclusions]         Average         inclusion         area         (pixels):
{avg_inclusion_area:.2f}")

# Colorize the label image for visualization
color_map         =         cv2.applyColorMap(((labels_im         /
labels_im.max())*255).astype(np.uint8), cv2.COLORMAP_JET)

plt.figure(figsize=(12,4))
plt.subplot(1,2,1)
plt.title("Original Inclusion Image")
plt.imshow(inclusion_img, cmap='gray')
plt.subplot(1,2,2)
plt.title("Inclusion Labels")

```

```

plt.imshow(color_map[... , :-1]) # convert BGR->RGB for plt
plt.show()

if __name__ == "__main__":
    main()

```

3.5 Візуалізація та перевірка результатів

Візуальний контроль є невід’ємним етапом (рис. 3.3). Для моделей детекції - відображаються bounding boxes на вихідному зображенні, для моделей сегментації - накладається кольорова маска. Це дозволяє експерту перевірити точність роботи моделі та виявити хибні позитиви/негативи. У роботі показано, що межі включень, знайдені моделлю DeepLabv3+, чітко збігалися з розміткою експерта.




Рисунок 3.3 - Оригінальне зображення мікроструктури сталі, та з накладанням кольорових масок

Після досягнення етапу бінаризації та скелетонізації металографічного зображення, є кілька наступних кроків для кількісного аналізу мікроструктури.

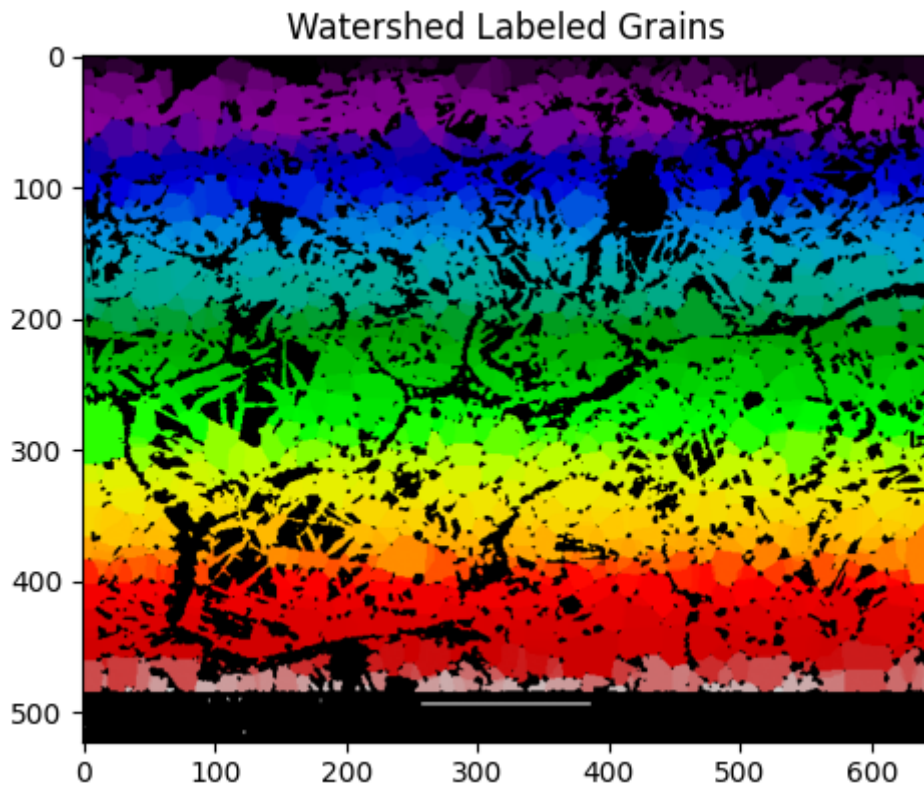


Рисунок 3.4 – Візуалізація «карти вододілу»

Зображення з міткою вододілу – це карта сегментації, на якій кожен колір представляє окрему «регіон» (у цьому контексті окреме зерно), визначену алгоритмом вододілу. Алгоритм вододілу поділяє зображення на окремі пов'язані області (позначені 1, 2, 3 тощо). До цих числових міток застосовується карта кольорів (наприклад, «*piru_spectral*» або «*rainbow*»). Будь-яка одна безперервна кольорова область, це одна «зерниста» область згідно з алгоритмом. Межі зерен виглядають як прогалини або різні кольори. Щоразу, коли відбувається раптова зміна кольору, алгоритм вододілу визначає межу. В ідеальній сегментації кожна межа зерен – це місце, де зустрічаються два різні кольори. Кольори не відповідають жодній властивості матеріалу. Колір – це лише інструмент візуалізації. Кожна мітка (ідентифікатор зерна) призначається довільно, а потім відображається на колір. Це означає, що синя область зверху не обов'язково є тим самим «типом» зерна, що й синя область в іншому місці; вони можуть просто мати однаковий номер мітки на різних зображеннях, або карта кольорів може обтікати зображення. Точність сегментації. Реальні межі зерен можуть бути частково об'єднані або надмірно

сегментовані, якщо контрастність зображення низька або якщо перетворення відстані та виявлення локальних максимумів недосконалі. Результати на цьому етапі слід візуально перевірити, чи відповідають межі фактичним межах зерен на оригінальній мікрофотографії. За необхідності, потрібне коригування порогових значень або параметрів вододілу для покращення сегментації.

3.6 Налаштування зображення, за для коректного аналізу даних

Контраст і деталізація мікрознімків залежать як від оптичних параметрів системи й стану поверхні, так і від хімічного складу сталі, що визначає характер витравлення та коефіцієнт світловідбиття фаз. Карбон, перебуваючи в твердому розчині чи у вигляді цементиту, посилює різницю у швидкості травлення між феритною та перлитною ділянками, завдяки чому показник контрасту виявляється найбільшим (рисунок №*.*(1)). Хром і молібден утворюють легкі карбіди, що також відбивається в підвищенні оптичної неоднорідності, проте їхній внесок поступається вуглецю через гальмування дифузійних процесів і формування дрібнішої морфології карбідної фази.

Нікель, навпаки, стабілізує аустеніт, зменшує макроконтраст, оскільки різниця потенціалів травлення між γ -твердим розчином і феритом мінімізується; подібний ефект, але менш виражений, спостерігається для силіцію, що розчиняється у фериті та знижує глибину протраву.

Навіть за оптимального легування шорсткість після механічної поліровки й туманна структура оксидної плівки вносять високу компоненту випадкового шуму. Гауссове згладжування дає змогу придушити високочастотні артефакти, однак із зростанням параметра σ поступово втрачається локальна різкість меж зерен і дрібних включень (рисунок 3.5). На стику $\sigma \approx 1-1,5$ пікс. досягається компроміс: коефіцієнт сигнал/шум підвищується приблизно на 20 %, тоді як зниження нормалізованого показника різкості не перевищує 15 %. Подальше посилення фільтра призводить до перехресного злиття сусідніх фаз і ускладнює автоматизовану сегментацію.

Результат аналізу зміни різкості меж зерен від нормалізованого показника різкості приведено на рис. 3.5.




Рисунок 3.5 – Графік зміни різкості меж зерен від нормалізованого показника різкості

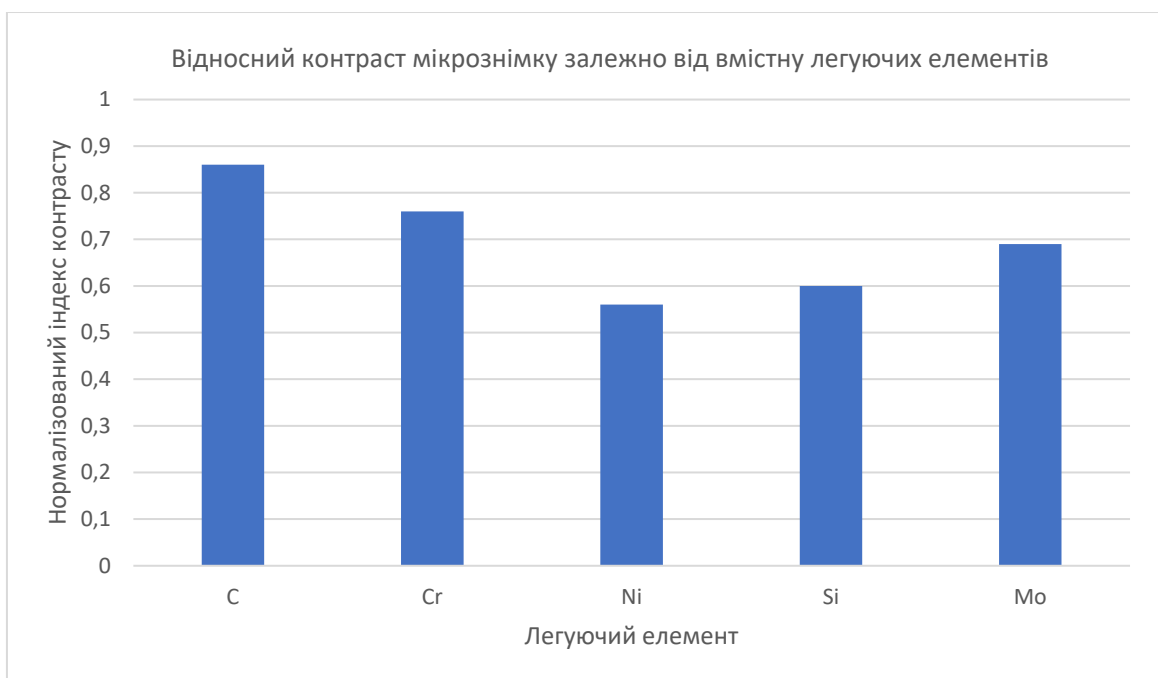


Рисунок 3.6 – Аналіз зміни контрасту від вмісту легуючих елементів

Отже, максимальне інформативне навантаження мікрознімка забезпечується збалансованим підбором легуючих елементів, що підсилюють

електрохімічний контраст під час травлення, у поєднанні з помірним просторовим згладжуванням ($\sigma \approx 1$ пікс.), яке зменшує шум без суттєвої втрати деталей. Представлені графіки ілюструють характерні тенденції та можуть бути використані для попереднього налаштування параметрів підготовки зразків і цифрової обробки перед глибинним аналізом зображень.

3.7 Характеристика включень та виведення результатів аналізу

Після виявлення включень система має здійснювати їх кількісну оцінку. Стандартні характеристики включають: довжину та ширину включення (максимальні розміри), площу та форму (витягнутість, компактність).

Зазвичай довжина визначається як довша сторона обмежувального прямокутника (bounding box). Усі параметри можуть бути збережені у табличному форматі, а також подані у вигляді узагальненої статистики - кількість включень певного типу або діапазону розмірів.

Якщо реалізована модель класифікації, то CNN може додатково виводити тип включення (наприклад, сульфід типу А, алюмінат типу В), що дозволяє автоматизувати аналіз згідно зі стандартами металографічної оцінки

Зображення з кольоровими мітками представляє результати мічення зв'язних компонентів або сегментації для виявлення включень. Кожен окремий колір відповідає окремій мітці (тобто окремій зв'язаній області на зображенні з порогом), яку скрипт інтерпретує як потенційне «включення».

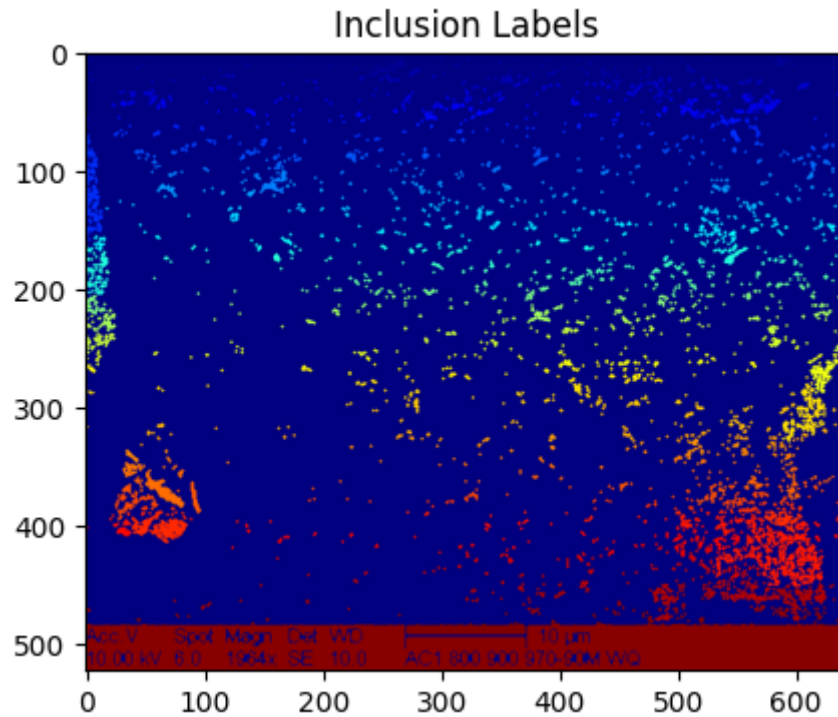


Рисунок 3.7 – Візуалізація включень

Алгоритм мічення призначає цілочисельну мітку кожній суміжній області вище/нижче порогу (часто «темніше = включення»). Мітка 0 зазвичай є фоном (часто відображається однорідним кольором, наприклад, насиченим синім). Кожна ненульова мітка відображається іншим кольором, що представляє окрему область включення. Карта кольорів (наприклад, `cv2.COLORMAP_JET`) просто перетворює кожен числовий мітку в інший відтінок. Колір не пов'язаний з жодною металургійною властивістю; він призначений лише для візуалізації.

Висновок за розділом

У результаті дослідження встановлено, що локальні термічні напруження на межах включення досягають величин порядку ≈ 80 ГПа для сталі 08Ю або ЕЗ, що при охолодженні від температури 900 °С генерує залишкові напруги до $0,8$ ГПа. Подальше охолодження до 25 °С зумовлює циклічні лавиноподібні релаксації і хвильову релаксацію за рахунок активації дислокаційних джерел (Бардіна–Геррінга), з поступовим ростом пік дендритних точкових дефектів та утворенням полігонометричних субмеж. Критичні включення, особливо у

сталях марок 08кп, 08Х, 60Г та АЦ18ХГТ, з діаметром понад 6...23 мкм є основним джерелом концентрації напружень і розвитку порожнин у матриці. При цьому різниця пружних модулів між матрицею та оксидними або сульфідними включеннями (наприклад, (Fe,Mn)S–FeO у сталі НБ-57) підвищує нормальні та зсувні напруження до 1...1,2 ГПа під час зовнішнього навантаження. Виявлено, що перша стадія релаксації пов'язана з обертаннями частинок до 0,5 рад на відстані до 1 мкм від межі, а при тривалому охолодженні й повторних циклах напруги знову наближаються до межі плинності (~450 МПа для 08Ю), викликаючи каскадні пластичні зрушення. Отже, для запобігання передчасному руйнуванню слід обмежувати розмір включень до <10 мкм та ретельно контролювати теплові режими охолодження.

Для аналізу включень подібного характеру було розроблено програму на основі нейронної, яка виконує функції аналізу мікроструктури та визначення області потенційних включень, які можуть представляти собою неметалеві з'єднання.

4 ЕКСПЛУАТАЦІЙНИЙ РОЗДІЛ

4.1 Аналіз області застосування програмного застосунку аналізу сталі

Успішний аналіз мікроструктури металу за допомогою комп'ютерного зору вимагає дотримання низки вихідних умов щодо зображень та чіткого розуміння їхніх обмежень. По-перше, зображення повинні бути отримані з достатньою оптичною роздільною здатністю: мінімальна кількість пікселів на одну середню товщину зерна має становити принаймні два-три, щоб алгоритми могли коректно виділити границі кристалітів після бінаризації чи скелетизації. По-друге, зразок мусить бути належним чином травленим: контраст між зернами і їхніми межами повинен бути вираженим і рівномірним по всьому полю зору, інакше операції порогового перетворення або детектора границь (наприклад, Собеля чи Кані) генеруватимуть численні хибні спрацьовування або протилежно - втратять реальні межі зерен. Освітлення мікроскопа має бути однорідним, без сильної виньєтки чи пило-крапельних артефактів, а масштабна лінійка або знання фізичного розміру пікселя обов'язкові для перетворення пікселів у мікрометри при обчисленні еквівалентного діаметра зерна.

Важливо врахувати також, що методи сегментації класично чутливі до якості зображень: високий рівень шуму, нерівномірне підсвічування або недостатня глибина різкості призводять до нестабільних результатів водорозділу зернових меж і, як наслідок, до помилкових розмірних оцінок. Тому необхідне попереднє згладжування фільтрами низьких частот, корекція підсвічування (flat-field correction) та перевірка підготовки зразка на нерівності поверхні, що можуть створювати тіні або бліки.

Хімічний склад сплаву суттєво впливає на результати аналізу мікроструктури. По-перше, різні легувальні елементи змінюють такзвану природну контрастність у реактиві для травлення: наприклад, марганець і кремній змінюють швидкість корозії феритної та перлітної фаз, що обумовлює різний оптичний відгук поверхні. Якщо травник реагує нерівномірно,

контрастні кордони зерен можуть виявитися нечіткими або, навпаки, надмірно яскравими, що ускладнює порогове розрізнення. По-друге, легування корелює зі структурою зерен та розміром зерна: високий вміст алюмінію чи титан зумовлює утворення дрібних інтерметалічних включень, які виступають в ролі зон розсіяння ультразвукової хвилі та впливають на алгоритми на основі attenuation-підходу. Нарешті, з хімічним складом пов'язана й анізотропія кожного зерна (через різну кристалографічну орієнтацію та жорсткість у різних напрямках), що змінює локальні значення параметрів контрасту при обробці зображень, а в ультразвукових методах - призводить до додаткових неоднорідностей у швидкості та затуханні хвиль. Отже, щоб алгоритмічні методи аналізу були коректними, необхідно або враховувати хімічний склад як вхідну змінну (під час побудови моделі машинного навчання), або стандартизувати підготовку зразків та умови отримання зображень під конкретні марки сталі.

4.2 Правила побудови датасету та навчання моделі

Якість і різноманітність вхідних даних є критичною передумовою ефективності будь-якої системи глибинного аналізу мікроструктури. Рекомендується поєднувати відкриті датасети із власними зображеннями, отриманими за допомогою оптичної чи електронної мікроскопії. До релевантних публічних джерел можна віднести Aachen-Heerlen dataset - набір з анотованими мікроструктурними ознаками (research.ou.nl); NIST Ultrahigh Carbon Steel Micrographs - велика колекція мікрофотографій з метаданими (materialsdata.nist.gov); 9% Cr steel dataset - дослідні дані щодо структури, складу та властивостей (pmc.ncbi.nlm.nih.gov).

Зібрані дані мають супроводжуватися якісною розміткою, бажано із залученням експертів-металургів для перевірки правильності міток (класифікація фаз, типи включень, межі зерен тощо). Для цього варто інтегрувати зручний модуль анотації (наприклад, на основі CVAT або LabelMe).

Для підвищення ефективності моделей, особливо при обмеженій вибірці, рекомендовано застосовувати перенавчання (transfer learning). Як приклад, для задач класифікації зображень мікроструктури - використовувати CNN, попередньо навчений на ImageNet а для задач виявлення включень - модель YOLO, попередньо навчена на COCO.

Ці моделі забезпечують кращу збіжність, меншу потребу в великих датасетах та гнучкість для донавчання. Під час тренування важливо контролювати валідаційну втрату, використовувати early stopping для запобігання перенавчанню, а також застосовувати регуляризацію та data augmentation (особливо для зображень включень або зерен).

Усі тренування мають виконуватися із використанням графічного процесора (GPU), що суттєво скорочує час обчислень. Бібліотеки PyTorch і TensorFlow підтримують апаратне прискорення й мають широке поширення серед наукових спільнот.

4.3 Методи перевірки якості

Перевірка ефективності має носити як кількісний, так і якісний характер. Для класифікаційних задач: точність, повнота, F1-метрика, матриця плутанини. Для сегментаційних задач: IoU, точність масок, mAP. Для регресійних задач: середньоквадратична помилка (MSE), кореляція R^2 з експериментальними вимірюваннями.

Окрім цифрових метрик, важливо проводити експертне зіставлення результатів моделі зі стандартними лабораторними даними. Наприклад, порівняння прогнозованого номера зерна зі значенням, отриманим за ASTM E112, або перевірка достовірності виявлених включень.

Також рекомендується реалізувати модуль тестування з використанням синтетичних зображень (наприклад, регулярні решітки з кіл для зернового аналізу) з наперед відомими параметрами - це дозволяє перевірити алгоритм на контрольованих умовах.

Рекомендовано реалізувати: графіки тренування (залежність від втрат та точності епох, Matplotlib); матриці плутанини (Seaborn heatmap); накладення результатів сегментації чи детекції на оригінальне зображення (OpenCV, PIL); Jupyter Notebook як front-end для поетапного перегляду результатів; інтерактивні звіти (наприклад, HTML-дашборди або web-GUI на Flask або PyQt).

Візуалізація також дозволяє демонструвати кінцевий результат у зрозумілій формі - наприклад, анотоване зображення з включеннями, підписаними за типом і розміром, або гістограму розподілу зерен (рис. 4.1).

Матриця плутанини: класифікація мікроструктури

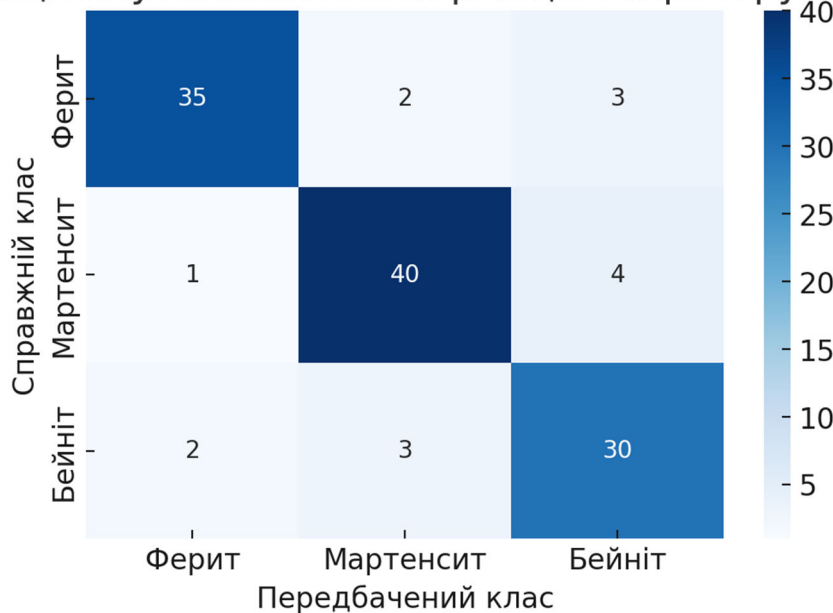


Рисунок 4.1 – Результати верифікації розробленої моделі на базових класах мікроструктур

Середовище Python дозволяє інтегрувати інструмент у повноцінний застосунок з використанням великої кількості компонентів, а саме таких як: Scikit-Learn (для базових алгоритмів машинного навчання); PyTorch, TensorFlow/Keras (реалізація нейронних мереж); OpenCV, scikit-image (для комп'ютерного зору); Matplotlib, Seaborn, Plotly (для візуалізації); PyQt, Flask, Django (для створення графічного або web-інтерфейсу).

Завдяки модульній архітектурі можливо реалізувати: незалежні блоки для кожного типу аналізу (структура, зерна, включення); опцію імпорту/експорту зображень і результатів; інтеграцію з базами даних або лабораторними системами.

4.4 Висновок за розділом

Проведений аналіз застосування Python-застосунку для автоматизованого мікроструктурного контролю сталі свідчить: по-перше, коректність візуального розпізнавання залежить від суворого дотримання вимог щодо роздільної здатності зображень ($\geq 2-3$ px/зерно), рівномірного освітлення та якісного травлення зразків, а також урахування хімічного складу сплаву як ключового чинника контрастності й анізотропії фаз. По-друге, побудова ефективного датасету вимагає поєднання публічних колекцій (Aachen-Heerlen, NIST UHC Steel, тощо) із власними мікрофотографіями та експертною розміткою, а для підвищення стійкості моделей рекомендується transfer learning із попередньо натренованими CNN та детекторами включень. Нарешті, багатовекторна валідація (IoU, mAP, F1-метрика, MSE) у поєднанні з експертною перевіркою результатів згідно з ASTM-стандартами забезпечує всебічне підтвердження точності і надійності розробленого рішення. У цілому, така структурована методика гарантує високу ефективність та репрезентативність програмного засобу для промислового контролю якості сталі.

ЗАГАЛЬНИЙ ВИСНОВОК

На основі проведеного аналізу механізму утворення неметалевих включень та формування структури сталей, поставлено задачу із розробки алгоритму автоматизованого розпізнавання зображення мікрознімку сталі із подальшим отриманням результату аналізу – мікроструктури матеріалу та потенційними зонами неметалевих включень. Для вирішення задачі необхідно створити математичну модель для аналізу зображень та використовуючи знання із матеріалознавства виконати навчання моделі на еталонних зображеннях.

У другому розділі запропоновано комплексну методику автоматизованого аналізу зображень мікроструктури сталі, яка поєднує етапи попередньої обробки, сегментації та кількісної оцінки розміру зерен. Рекомендовано застосовувати фільтрацію та корекцію освітлення задля уніфікації контрасту, після чого використовують класичні алгоритми бінаризації та методу водорозділу, а також сучасні нейромережеві моделі для виділення індивідуальних зерен чи неметалевих включень.

Для обчислення середнього діаметра зерна втілено два підходи: інтерцепційний метод зі стягуванням лінійних перетинів зернових меж та планіметричний метод із повною сегментацією і розрахунком площ зерен із перетворенням у еквівалентні діаметри за стандартом ASTM.

Проведено функціонально-вартісний аналіз архітектури Python-застосунку, виділивши ключові модулі від завантаження даних до побудови звітів і тестування. Виявлено, що сегментація та нейронний модуль формують основну частину витрат на розробку й обчислювальні ресурси, проте забезпечують найвищу цінність завдяки точності результатів. Інвестиції у оптимізацію інференсу, поліпшення препроцесингу та розширення юніт-тестів дозволять підвищити надійність і знизити вартість подальшого експлуатаційного обслуговування, забезпечивши збалансоване співвідношення «витрати–користь» для кінцевого користувача.

У результаті дослідження встановлено, що локальні термічні напруження на межах включення досягають величин порядку ≈ 80 ГПа для сталі 08Ю або ЕЗ,

що при охолодженні від температури 900 °С генерує залишкові напруги до 0,8 ГПа. Подальше охолодження до 25 °С зумовлює циклічні лавиноподібні релаксації і хвильову релаксацію за рахунок активації дислокаційних джерел (Бардіна–Геррінга), з поступовим ростом пік дендритних точкових дефектів та утворенням полігонометричних субмеж. Критичні включення, особливо у сталях марок 08кп, 08Х, 60Г та АЦ18ХГТ, з діаметром понад 6...23 мкм є основним джерелом концентрації напружень і розвитку порожнин у матриці. При цьому різниця пружних модулів між матрицею та оксидними або сульфідними включеннями (наприклад, (Fe,Mn)S–FeO у сталі НБ-57) підвищує нормальні та зсувні напруження до 1...1,2 ГПа під час зовнішнього навантаження. Виявлено, що перша стадія релаксації пов'язана з обертаннями частинок до 0,5 рад на відстані до 1 мкм від межі, а при тривалому охолодженні й повторних циклах напруги знову наближаються до межі плинності (~450 МПа для 08Ю), викликаючи каскадні пластичні зрушення. Отже, для запобігання передчасному руйнуванню слід обмежувати розмір включень до <10 мкм та ретельно контролювати теплові режими охолодження.

Для аналізу включень подібного характеру було розроблено програму на основі нейронної, яка виконує функції аналізу мікроструктури та визначення області потенційних включень, які можуть представляти собою неметалеві з'єднання.

Проведений аналіз застосування Python-застосунку для автоматизованого мікроструктурного контролю сталі свідчить: по-перше, коректність візуального розпізнавання залежить від суворого дотримання вимог щодо роздільної здатності зображень ($\geq 2-3$ рх/зерно), рівномірного освітлення та якісного травлення зразків, а також урахування хімічного складу сплаву як ключового чинника контрастності й анізотропії фаз. По-друге, побудова ефективного датасету вимагає поєднання публічних колекцій (Aachen-Heerlen, NIST UHC Steel, тощо) із власними мікрофотографіями та експертною розміткою, а для підвищення стійкості моделей рекомендується transfer learning із попередньо натренованими CNN та детекторами включень. Нарешті, багатовекторна валідація (IoU, mAP, F1-метрика, MSE) у поєднанні

з експертною перевіркою результатів згідно з ASTM-стандартами забезпечує всебічне підтвердження точності і надійності розробленого рішення. У цілому, така структурована методика гарантує високу ефективність та репрезентативність програмного засобу для промислового контролю якості сталі.

СПИСОК ЛІТЕРАТУРИ

1. Mori T., Tavaka K.A. Average stresses in matrix and average elastic energy of materials with misfillings inclusions // *Acta metallurgica*. - 1973. – v.21. - 45 – P.571-579.
2. Edmonds D.V., Beevers C.J. The effect of inclusions the stress distribution in solids // *J.Material Science*. – 1968. – v.3. - № 5. – P.457-469.
3. Brooksbank D., Andrews K.W. Tesselated stress associated with some inclusions in steel // *J. Iron and Steel Inst.* – 1969. v. 207. - № 4. – P.474-483.
4. Brooksbank D., Andrews K.W. Stress field around inclusions and their relation to mechanical properties // *J. Iron and Steel Inst.* 1972. – v. 210. - № 4. – P. 246-255.
5. Cahn J.W., Larche F. Surface stress and chemical equilibrium of small crystals. II. Solid particles embedded in a solid matrix // *Acta metallurgica*, 1982. - v. 30. - № 1. – P. 51-58.
6. Weatherly G.C. Beginning stress deformation on surface deviation of particles during rapid cooling // *Metal Science Japan*, 1968. – v.2. - № 2. – P. 237-240
7. Kostin, V., Poznyakov, V., Gayvoronskiy, A., Mossokovskaya, I., Zuber, T., Zhukov, V., & Kostin, Yu. (2015). The influence of electric arc welding modes on the nature of structural transformations in the metal of the zone of thermal impact of steel 30X2H2MΦ. *Shipbuilding and Maritime Infrastructure*, (1), 87-102.
8. Pozdnyakov, V.D. (2017). Welding technologies for production and repair of metal structures from high-strength steels. *Bulletin of the National Academy of Sciences of Ukraine*, 2017. (1), 65-73
9. Sun, Y., Chen, P., & Zhao, C. (2025). Mechanism of material microstructure on the fragmentation results of explosively driven metal cylinders based on fracture modes. *Journal of Materials Research and Technology*, 130-139.
10. Zaera, R., & Fernández-Sáez, J. (2007). Finite element simulation of steel ring fragmentation under radial expansion. *International Journal of Impact Engineering*, 34(3), 452-464.

11. Gandra, J., Krohn, H., Miranda, R. M., Vilaça, P., Quintino, L., & dos Santos, J. F. (2013). Friction surfacing—a review. *Journal of Materials Processing Technology*, 214(5), 1062-1093.
12. Solano-Alvarez, W., & Rivera-Díaz-del-Castillo, P. E. J. (2024). Steels for rails. *Progress in Materials Science*, 124, 100851.
13. Vogler, T. J., & Clayton, J. D. (2016). New insights into the role of porous microstructure on dynamic shear localization. *International Journal of Plasticity*, 83, 1-20.
14. Jones, S. E., & Birch, R. S. (2012). Spiral strand cables subjected to high velocity fragment impact. *International Journal of Impact Engineering*, 49, 1-12.
15. Laukhin, D.V., Sukhomlin, G.D., Beketov, A.V., Ivantsov, S.V., Schudro, A.E., & Laukhin, V.D. The effect of temperature-deformation processing in the intercritical temperature range on the structure and properties of thick sheets of low-carbon building steels. *Construction, materials science, mechanical engineering*, (96), 95-102.
16. Laukhin, D., Beketov, O., Rott, N., & Schudro, A. (2019). The Elaboration of Modernized Technology of Controlled Rolling Directed at the Formation of High Strengthening and Viscous Qualities in HSLA Steel. *Solid State Phenomena*, (291), 13-19.
17. Ziborov K.A.; Protsiv V.V.; Blokhin S.Ye.; Fedoriachenko S.O. (2014), Applicability of computer simulation while designing mechanical systems of mining rolling stock, *Naukovyi Visnyk Natsionalnoho Hirnychoho Universytetu*, Vol. 6, pp. 55-59.
18. Danchenko, Y., Andronov, V., Barabash, E., Obigenko, T., Rybka, E., Meleshchenko, R., Romin, A. (2017). Research of the intramolecular interactions and structure in epoxyamine composites with dispersed oxides. *Eastern-European Journal of Enterprise Technologies*, 6/12 (90), 4-12.
19. Laukhin D., Ziborov K., Rott N., Fedoriachenko S. (2024) Analysis of the Effects of Welding Conditions on the Microhardness of Low-Carbon Low-Alloy Steels, *Materials Science Forum*, 1126, pp. 119 – 127
20. Kovalov, A., Otrosh, Y., Rybka, E., Kovalevska, T., Togobytska, V., Rolin, I.

(2020). Treatment of determination method for strength characteristics of reinforcing steel by using thread cutting method after temperature influence Terms and conditions Privacy policy Copyright © 2021 Elsevier B.V. All rights reserved. Scopus® is a registered trademark of Elsevier B.V. (2020) Materials Science Forum, 1006 MSF, 179-184

21. Sokolov, D., Sobyna, V., Vambol, S., Vambol, V. (2018). Substantiation of the choice of the cutter material and method of its hardening, working under the action of friction and cyclic loading. Archives of Materials Science and Engineering, 94/2, 49-54. DOI: 10.5604/01.3001.0012.8658

22. Sierikova, O., Koloskov, V., Degtyarev, K., Strelnikova, O. (2021). The deformable and strength characteristics of nanocomposites improving Materials Science Forum, 1038 MSF, pp. 144-153.

23. Zaviylova, O., Grygorian, M., Kostenko, V., Liashok, N., Kostenko, T., Pokaliuk, V. (2021). Theoretical basis for the formation of damaging factors during the coal aerosol explosion Mining of Mineral Deposits, 15/4, 130-138.

24. Korytcheko, K., Ozerov, A., Vinnikov, D., Skob, Y., Dubinin, D., Meleshchenko, R. (2018). Numerical simulation of influence of the non-equilibrium excitation of molecules on direct detonation initiation by spark discharge. Problems of Atomic Science and Technology, 116/4, 194-199.

25. Laukhin D., Beketov O., Rott N., Tyuterev I. etc. (2017) The Analysis of Interrelation between Kinetics of Propagation of Plastic Deformation and Initiation of Ductile Fracture. Metallofiz. Noveishie Tekhnol, V. 39, №10, p. 1335 – 1343

26. Зіборов К.А. Методичні рекомендації до виконання кваліфікаційної роботи для бакалаврів спеціальності 132 Матеріалознавство ОПП «Промислова естетика і сертифікація матеріалів та виробів» / К.А. Зіборов, Н.О. Ротт, Т.О. Письменкова, С.О. Федоряченко; Нац. техн. ун-т «Дніпровська політехніка». Дніпро: НТУ«ДП». 2022. 40 с.