

DOI: 10.21122/2220-9506-2024-15-3-231-239

Применение технологий искусственного интеллекта для оперативной диагностики механических характеристик чугуна

А.Ю. Кутепов¹, А.П. Крень¹, А.В. Никифоров², Н.К. Турсунов³

¹Институт прикладной физики Национальной академии наук Беларуси,
ул. Академическая, 16, г. Минск 220072, Беларусь

²Белорусский государственный университет,
ул. Курчатова, 1, г. Минск 220064, Беларусь

³Ташкентский государственный транспортный университет,
ул. Темиръулчиляр, 1, г. Ташкент 100167, Узбекистан

Поступила 30.07.2024

Принята к печати 10.09.2024

Кинетическое индентирование широко используется для измерения физико-механических свойств материалов, как один из наиболее универсальных методов неразрушающего контроля. В настоящей работе использованы новейшие достижения в области искусственного интеллекта и возможности библиотек языка программирования Питон, позволяющие на основании данных диаграммы микроударного нагружения материала провести точные измерения твёрдости чугунов различных марок. Показано, что применение машинного обучения позволяет устранить грубые ошибки и снизить погрешность косвенного определения твёрдости в несколько раз – до 10 единиц по Бринеллю НВ. Также установлено, что формирование дополнительных признаков для обучения моделей (на основании традиционно используемых характеристик: глубин внедрения, скорости перемещения индентора и контактных усилий в определённые моменты времени) положительным образом сказывается на точности измерений, однако при этом их количество также должно быть оптимизировано. Возможность эффективного использования машинного обучения для оценки твёрдости доказана путём сравнения расчётных значений твёрдости с данными, полученными стандартными методами испытаний. Достоинством разработанной методики контроля является то, что разработанные алгоритмы могут применяться для оперативной диагностики твёрдости чугуна с использованием уже существующего оборудования. Предложенный подход представляется целесообразным распространить на определение других механических характеристик чугуна: предела текучести, показателя деформационного упрочнения, ползучести, релаксации, определяемых методами индентирования.

Ключевые слова: индентирование, чугун, искусственный интеллект, машинное обучение, твёрдость

Адрес для переписки:

Крень А.П.
Ин-т прикладной физики Национальной академии наук Беларуси,
ул. Академическая, 16, г. Минск 220072, Беларусь
e-mail: 7623300@gmail.com

Address for correspondence:

Kren A.P.
Institute of Applied Physics of the National Academy of Science of Belarus,
Akademicheskaya str., 16, Minsk 220072, Belarus
e-mail:7623300@gmail.com

Для цитирования:

А.Ю. Кутепов, А.П. Крень, А.В. Никифоров, Н.К. Турсунов.
Применение технологий искусственного интеллекта для оперативной диагностики механических характеристик чугуна. Приборы и методы измерений. 2024. Т. 15. № 3. С. 231–239.
DOI: 10.21122/2220-9506-2024-15-3-231-239

For citation:

Kutsepau A, Kren A, Nikiforov A, Tursunov N.
Application of Artificial Intelligence Technology for Prompt Diagnosis of Cast Iron Mechanical Properties. Devices and Methods of Measurements. 2024;15(3):231–239. (In Russ.).
DOI: 10.21122/2220-9506-2024-15-3-231-239

DOI: 10.21122/2220-9506-2024-15-3-231-239

Application of Artificial Intelligence Technology for Prompt Diagnosis of Cast Iron Mechanical Properties

A. Kutsepau¹, A. Kren¹, A. Nikiforov², N. Tursunov³

¹*Institute of Applied Physics of the National Academy of Science of Belarus,
Akademicheskaya str., 16, Minsk 220072, Belarus*

²*Belarussian State University,
Kurchatov str., 1, Minsk 220064, Belarus*

³*Tashkent State Transport University,
Temiryulchilar str., 1, Tashkent 100167, Yzbekistan*

Received 30.07.2024

Accepted for publication 10.09.2024

Abstract

Kinetic indentation is widely used to measure physical and mechanical properties of materials as one of the most universal methods for non-destructive testing. This paper uses the latest advances in artificial intelligence and capabilities of the Python programming language libraries allowing to carry out accurate measurements of cast iron hardness based on the data of the material's micro-impact loading diagram. It has been shown that use of machine learning allows eliminating gross errors and reducing the error of indirect hardness evaluation in several times – down to 10 units according to Brinell HB. It has also been established that formation of additional features for training models (based on traditionally used characteristics: penetration depths, indenter movement speed and contact forces at certain points in time) has a positive effect on the accuracy of measurements, but amount of measurements should also be optimized. Feasibility of effective use of machine learning to evaluate hardness has been demonstrated by comparing of calculated hardness values with data obtained with standard testing methods. Advantage of the developed testing method is the fact that the developed algorithms can be used for prompt diagnostics of cast iron hardness using existing equipment. It is appropriate to extend the proposed approach for determination of other mechanical properties of cast iron: yield strength, strain hardening index, creep, relaxation, determined by indentation methods.

Keywords: indentation, cast iron, artificial intelligence, machine learning, hardness

Адрес для переписки:

Крень А.П.

*Ин-т прикладной физики Национальной академии наук Беларуси,
ул. Академическая, 16, г. Минск 220072, Беларусь
e-mail: 7623300@gmail.com*

Address for correspondence:

Kren A.P.

*Institute of Applied Physics of the National Academy of Science of Belarus,
Akademicheskaya str., 16, Minsk 220072, Belarus
e-mail:7623300@gmail.com*

Для цитирования:

А.Ю. Кутепов, А.П. Крень, А.В. Никифоров, Н.К. Турсунов.
Применение технологий искусственного интеллекта
для оперативной диагностики механических характеристик чугуна.
Приборы и методы измерений.
2024. Т. 15. № 3. С. 231–239.
DOI: 10.21122/2220-9506-2024-15-3-231-239

For citation:

Kutsepau A, Kren A, Nikiforov A, Tursunov N.
Application of Artificial Intelligence Technology for Prompt Diagnosis
of Cast Iron Mechanical Properties.
Devices and Methods of Measurements.
2024;15(3):231–239. (In Russ.).
DOI: 10.21122/2220-9506-2024-15-3-231-239

Введение

Чугун является одним из основных материалов, используемых в машиностроительном производстве. Его широкое применение обусловлено достаточно высокими механическими характеристиками при относительной простоте выплавки. Разработка новых техпроцессов и легирование привели к появлению высокопрочных чугунов с улучшенными характеристиками. Однако до настоящего времени существует проблема получения чугуна с заданными свойствам в такой степени, чтобы можно было предсказывать с полной уверенностью его структуру после плавки и термической обработки. При выплавке чугуна необходимо строгое соблюдение технических условий его производства, включая химический состав, распределение температуры по объёму отливки, время проведения той или иной операции и др. [1, 2]. Даже небольшие отклонения параметров от заданных в технических условиях в комплексе могут привести к выпуску партии отливок с негодной микроструктурой и физико-механическими свойствами. Это вызывает необходимость изготовления образцов-свидетелей при плавке и проведение исследований структуры и свойств полученного чугуна.

В подавляющем большинстве случаев на предприятиях контроль структуры чугуна осуществляется разрушающими методами, включая металлографию, испытания на разрыв, твёрдость и др. При высокой информативности эти методы трудоёмки и длительны. Применение неразрушающих методов, как правило, ограничивается магнитным и ультразвуковым методами, которые тоже обладают рядом ограничений.

Одним из наиболее перспективных, по нашему мнению, является метод динамического индентирования. В отличие от стандартных методов измерения твёрдости он не требует создания замкнутой силовой системы для вдавливания индентора и может применяться для контроля изделий сложной формы. Недостатком его является тот факт, что сведения о чугуне берутся с поверхностных слоев, однако для изделий, прошедших механическую обработку, этот недостаток нивелируется. В тоже время, как показывает практика, дина-

мические характеристики не всегда имеют устойчивую связь со статическими вследствие различия в достигаемых деформациях и скоростях деформации. Задача установления такой связи может успешно решаться с помощью инструментов искусственного интеллекта (ИИ) [3], которые широко используются в различных исследованиях для увеличения точности предсказания того или иного параметра материала [4, 5]. При этом широкое распространение получили такие средства для автоматизации процессов машинного обучения, как, например, библиотека PyCaret языка программирования Python, продукт Automated ML облачной платформы Azure и др., которые упрощают использование ИИ и расширяют области возможного применения [6].

Целью настоящей работы являлось изучение возможности контроля твёрдости по Бригеллю НВ чугуна методом ударного микроиндентирования с использованием диаграммы нагружения материала и обработки данных с помощью такого инструмента искусственного интеллекта как машинное обучение.

Оборудование и материалы

В отличие от традиционного измерения твёрдости методом статического вдавливания индентора динамическое инструментальное индентирование подразумевает регистрацию всей диаграммы нагружения, когда индентор находится в контакте с испытуемым материалом (рисунок 1).

Эта диаграмма позволяет определить целый набор данных: значение максимального контактного усилия P_{\max} , глубину максимального h_{\max} , упругого h_e и пластического h_p внедрения, диаметр контактного отпечатка d_c , скорость подлёта V_{\max} и отскока индентора V_{\min} , время активного этапа удара t_a , коэффициент восстановления скорости $e = V_{\min}/V_{\max}$, энергию упругого W_e и пластического деформирования W_p [7]. Эти параметры позволяют рассчитать динамическую твёрдость H_d [8, 9], модуль упругости E , пластичность δ и др. Однако, как показывают исследования, значение H_d плохо коррелирует со статической твёрдостью [10].




Рисунок 1 – Характерные зависимости внедрения индентора в чугуны: *a* – изменение скорости в процессе ударного контакта; *b* – силовая диаграмма нагружения *c* – схема отпечатка

Figure 1 – Characteristic dependencies of indenter's penetration in cast iron: *a* – velocity change during the impact contact; *b* – force-penetration diagram; *c* – imprint scheme

При наличии достаточно развитой теории определения динамических характеристик материалов связь между ними не всегда является очевидной. Для её установления необходим трудозатратный анализ, позволяющий определить степень взаимовлияния определяемых свойств и который мог бы повысить точность их измерения.

В настоящей работе данные для машинного обучения были получены с помощью прибора ИФМХ-Ч [11] с тремя датчиками, которые отличались между собой массой m , радиусом R и скоростью подлёта индентора V_{\max} , как представлено в таблице 1. Данный прибор позволяет определить динамическую твёрдость и указанные ранее параметры.

Таблица 1 / Table 1

Параметры инденторов датчиков прибора ИФМХ-Ч

IFMH-CH sensors' indenter characteristics

Номер датчика	m , г	R , мм	V_{\max} , м/с
Transducer number	m , g	R , mm	V_{\max} , m/s
119	3.775	0.6	2.05
026T	3.889	1.0	1.66
007	3.805	0.9	1.88

Измерения проводились на 79 образцах чугуна, имеющего различную структуру: высокопрочном, сером, передельном,

с вермикулярным графитом. Параметры сигнала и характеристики (основные признаки, используемые в дальнейшем для машинного обучения) (таблица 2), полученные на каждом из образцов, усреднялись по десяти измерениям.

Таблица 2 / Table 2

Основные признаки, использованные для обучения моделей

Main features used to train models

P_{\max}	Максимальное усилие / Maximum force
h_{\max}	Максимальная глубина внедрения / Maximum penetration depth
h_p	Глубина остаточного отпечатка (пластическая составляющая внедрения) / Plastic imprint
h_e	Упругая составляющая глубины вдавливания индентора / Elastic penetration depth
d_c	Диаметр контактного отпечатка / Contact diameter
W_y	Энергия упругого деформирования / Elastic energy
E	Модуль упругости / Elastic modulus
H_d	Динамическая твёрдость / Dynamic hardness
V_{\min}	Скорость отскока индентора / Rebound velocity
t_a	Время активного этапа удара / Time of active part of impact
e	Коэффициент восстановления скорости / Restitution coefficient
δ	Пластичность / Plasticity

Значения статической твёрдости по Бринеллю, которая была искомым значением при обучении моделей, находились в диапазоне от 112 до 441 НВ и были измерены на статическом твердомере Бринелля в соответствии с ГОСТ 9012-59 [12].

Обработка данных и результаты

Для обучения моделей использовался язык программирования Python. При этом нами было изучена эффективность использования для обучения только основных признаков, представленных в таблице 2 (вариант 1), и обучения с использованием полиномиальных признаков, полученных из дополнительных признаков, формируемых путём различных математических операций, и основных (вариант 2). Для каждого датчика обучение

проводилось отдельно. Для всех вариантов автоматическая обработка данных, обучение, валидация и сравнение моделей производились с помощью библиотеки PyCaret. Из четырёх доступных модулей для установления целевого типа модели машинного обучения в PyCaret (классификация, регрессия, кластеризация и поиск аномалий) был использован модуль регрессии. Сравнение проводилось по таким метрикам, как: средняя абсолютная ошибка (MAE), средняя квадратичная ошибка (MSE), корень средней квадратичной ошибки (RMSE), коэффициент детерминации (R^2), среднеквадратическая логарифмическая ошибка (RMSLE), средняя абсолютная процентная ошибка (MAPE) и время обучения (TT).

Результаты сравнения моделей при обучении только по основным признакам (вариант 1) представлены в таблице 3.

Таблица 3 /Table 3

Сравнение метрик для различных моделей Metrics comparison of different models

Модель/ Model	MAE	MSE	RMSE	R^2	RMSLE	MAPE	TT, c/ TT, s
Linear Regression	13.3	318	17.5	0.938	0.078	0.059	1.83
Ridge Regression	14.0	337	18.2	0.932	0.083	0.065	0.03
Lasso Regression	14.3	346	18.5	0.931	0.090	0.068	0.04
Elastic Net	14.2	346	18.5	0.931	0.090	0.068	0.03
Lasso Least Angle Regression	14.1	344	18.4	0.930	0.084	0.066	0.03
Bayesian Ridge	14.9	401	19.9	0.921	0.089	0.068	0.03
Extra Trees Regressor	15.6	534	22.2	0.887	0.111	0.080	0.14
Random Forest Regressor	17.3	548	22.8	0.884	0.112	0.086	0.18
Gradient Boosting Regressor	16.7	568	23.4	0.881	0.113	0.081	0.10
AdaBoost Regressor	18.9	628	24.5	0.868	0.118	0.092	0.10
Extreme Gradient Boosting	19.1	765	27.5	0.838	0.134	0.094	0.08
Decision Tree Regressor	21.5	825	28.3	0.819	0.136	0.104	0.03
LGBBoosting Machine	46.5	3450	55.6	0.401	0.219	0.193	0.26

Как видно из таблицы 3, наиболее оптимальной моделью является линейная регрессия, обладающая наименьшими значениями MAE , MSE , $RMSE$, $RMSLE$, $MAPE$ и наибольшим R^2 . Выбранная модель прошла повторное обучение с 50 итерациями k -блочной кросс-валидации, определением оптимального количества признаков при ранжировании по важности с использованием модуля `SelectFromModel` библиотеки `Scikit-learn` и оптимизацией по MAE . Характеристики обученной модели представлены на рисунках 2 и 3. Из рисунка 2 видно, что оптимальным количеством признаков для обучения модели было 6. Этими признаками являлись P_{max} , h_p , d_c , V_{min} , δ , e .

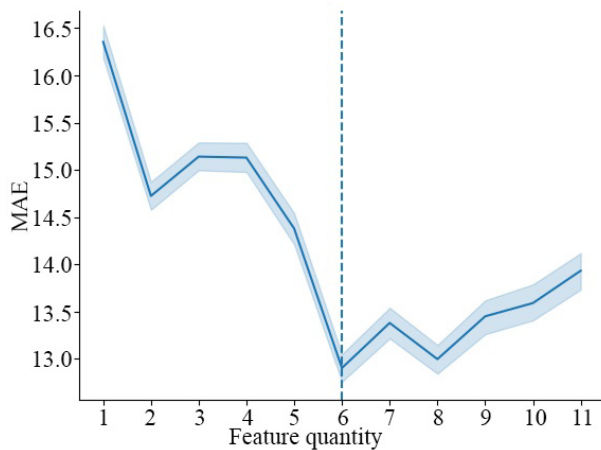


Рисунок 2 – Выбор оптимальных параметров по зависимости средней абсолютной ошибки от количества признаков

Figure 2 – Choose of optimal characteristics via mean absolute error dependency on the amount of features

Из рисунка 3 видно, что невязка – разница между измеренной и предсказанной моделью твёрдостью ΔHB – не зависит от значения абсолютного значения HB . При этом для тестируемой модели значение R^2 было равным 0,924, что меньше чем в таблице 3, поскольку использовалось меньшее количество итераций – 5.

С целью возможного улучшения точности модели были сконструированы дополнительные признаки (2-й вариант обучения), а также полиномиальные признаки 2-й степени, которые формировались из основных и дополнительных (3-й вариант). Признаки были получены при помощи модуля `PolynomialFeatures` библиотеки `sklearn.preprocessing`, дополнительно использовалась библиотека автоматической

генерации признаков `AutoFeat`. Дополнительные и полиномиальные признаки генерировались для полного набора исходных данных (таблица 2).




Рисунок 3 – Разница между измеренным и предсказанным значением твёрдости ΔHB для модели, использующей линейную регрессию

Figure 3 – Difference between measured and predicted hardness ΔHB for a linear regression model

На рисунке 4 представлена матрица корреляций между основными признаками (от P_{max} до e), дополнительными признаками (от $v_{min} \cdot \log(e)$ до $1/h_p$) и целевым параметром – HB . Из рисунка 4 видно, что дополнительные признаки не обладают большей корреляцией с твёрдостью, чем основные. Кроме того, библиотекой `AutoFeat` были подобраны разные дополнительные признаки для разных датчиков: например, признак $H_d^3 \cdot h_p^{1/2}$ обладал наибольшей корреляцией с HB среди дополнительных признаков для датчика 119, однако отсутствовал среди дополнительных признаков для двух других датчиков. Это означает, что общие новые признаки, которые можно было бы использовать для любого датчика, подключаемого к прибору ИФМХ-Ч не были обнаружены. Однако при создании дополнительных признаков для каждого отдельного датчика можно добиться некоторого улучшения точности модели.

При обучении моделей с полиномиальными признаками с помощью библиотеки `PyCaret` оптимальное количество признаков для обучения повысилось до 13 (P_{max} , h_{max} , h_p , h_e , d_c , W_y , H_d , V_{min} , t_a , δ , e , $H_d^{1/2} \cdot h_{max}$, $V_{min} \cdot \log(e)$), из которых далее формировались полиномиальные 2-й степени. На рисунке 5 представлен график зависимости предсказанного значения от истинного. Как можно заметить, моделям с полиномиальными

признаками не свойственны наличие выбросов, нелинейность в предсказании или сильное смещение.




Рисунок 4 – Матрица корреляций признаков

Figure 4 – Feature correlation matrix





Рисунок 5 – Зависимость предсказанного значения HB от истинного для модели с полиномиальными признаками

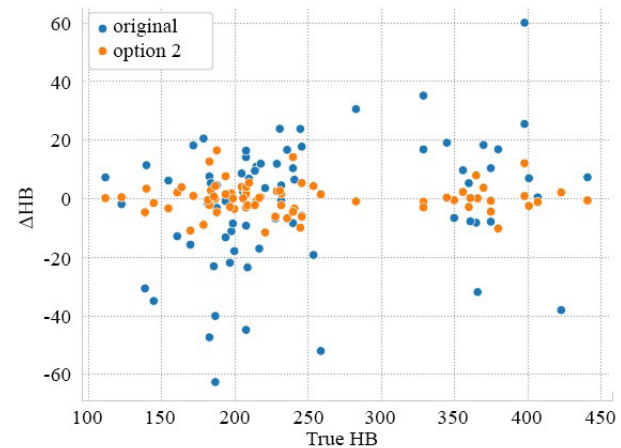
Figure 5 – Dependency plot of predicted HB value on true HB value for a regression model with polynomial features

После обучения были рассчитаны невязки оценки твёрдости и истинного значения твёрдости, измеренной прибором ИФМХ-Ч (используя алгоритм, изложенный в [11]); для модели, использующей основные признаки; и для модели с полиномиальными признаками.

Графики ядерной оценки плотности ΔHB [13] и зависимости ΔHB от истинного значения для датчика 026Т представлены на рисунке 6.



a



b

Рисунок 6 – Распределение погрешностей обученных моделей при использовании датчика 026Т: ядерная оценка плотности ΔHB (a) и зависимость ΔHB от истинного значения HB (b)

Figure 6 – Trained model's error distribution for 026T transducer: kernel distribution estimation of ΔHB (a) and dependency of ΔHB on the true HB value (b)

Из рисунка 6 видно, что мода распределения ΔHB для модели с дополнительными и полиномиальными признаками (вариант 2) меньше, чем мода распределения ΔHB прибора (исходная) и линейной модели (вариант 1) – 2,86 и 9,43 соответственно. Для линейной и полиномиальной моделей использован двухсторонний критерий Колмогорова–Смирнова (D - P) [14]. Рассчитанное значение величины D составило 0,42, а значение P – менее 0,0001.

Это говорит о том, что выборки, полученные при помощи данных моделей, являются статистически различными, причём стандартное отклонение выборки, полученной при помощи модели с полиномиальными признаками меньше, чем в случае линейной модели – 4,48 против 10,48, соответственно. Аналогичное наблюдается и для выборки, полученной при помощи прибора, стандартное отклонение которой равно 12,51.

Также на рисунке 7 показана погрешность измерения твёрдости.

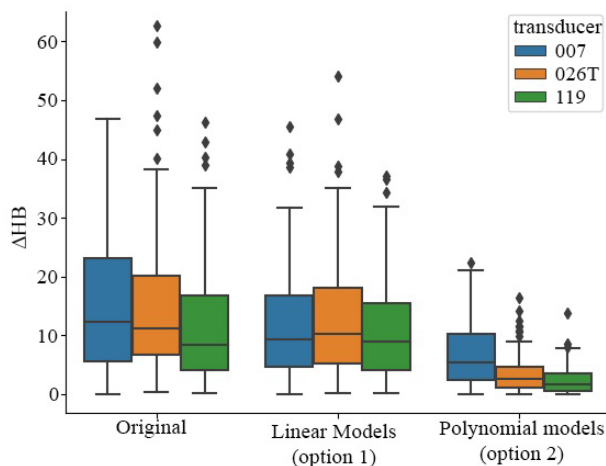


Рисунок 7 – Погрешности измерения твёрдости

Figure 7 – Hardness measurement error

Из рисунка (построенного для всех датчиков) видно, что значения ΔHB обученных моделей (вариант 2) не превышает 25 НВ, в то время как ΔHB для измерений, проведенных прибором ИФМХ-Ч, превышают 60 НВ.

Заключение

Рассмотрено использование инструментов машинного обучения для прогнозирования значений статической твёрдости по Бринеллю по данным динамического индентирования. Показано, что применение стандартных библиотек языка программирования Python позволяет устранить грубые ошибки измерения и снизить погрешность косвенного определения твёрдости в 2 раза. При этом в большинстве случаев эта погрешность не превышает 10 НВ, что является недостижимым результатом при использовании обычных эмпирических зависимостей между динамической и статической твёрдостью. Также установлено, что формирование дополнительных признаков положительным образом

сказывается на точности измерений, однако при этом их количество также должно быть оптимизировано.

Благодарности

Работа выполнена при поддержке Белорусского республиканского фонда фундаментальных исследований. Конкурс БРФФИ–МИРРУ 2023. Проект Т23УЗБ-035 «Изучение процессов структурообразования и локального деформирования чугунов с целью создания их улучшенных марок, методик и средств неразрушающего контроля физико-механических характеристик».

Acknowledgments

The work was done with the support of Belarusian Republican Foundation for Fundamental Research. Contest BRFFR-MIRRU 2023. Project T23УЗБ-035 «Study of structure forming processes and local deformation of cast iron aiming at creating their improved grades, methods and tools of non-destructive testing of their physical and mechanical properties».

Список использованных источников / References

1. Roy E. Cast iron technology. Butterworth-Heinemann. 2014;252 p.
DOI: 10.1016/B978-0-408-01512-7.50001-X
2. Ferro P. Cast Irons: Properties and Applications. Mdpi AG. 2020;150 p.
3. Bharadiya JP, Reji TK, Farhan A. Rise of Artificial Intelligence in Business and Industry. Journal of Engineering Research and Reports. 2023;3(25):85-103.
DOI: <https://doi.org/10.9734/jerr/2023/v25i3893>
4. Shahhosseini M. [et al.]. Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt. Sci Rep. 2021;(11):1606 p.
DOI: 10.1038/s41598-020-80820-1
5. Xin D. [et al.]. Whither AutoML? Understanding the Role of Automation in Machine Learning Workflows. In Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems (CHI '21). 2021;(83):1-16.
DOI: 10.1145/3411764.3445306
6. Lu J, Suresh S. Dynamic indentation for determining the strain rate sensitivity of metals. Mech Phys Solid. 2003;(51):11-12.
DOI: 10.1016/j.jmps.2003.09.007

7. Hassani M. [et al.]. Material hardness at strain rates beyond 106 s⁻¹ via high velocity microparticle impact indentation. *Scripta Mater.* 2020;(177):198-202.

DOI: 10.1016/j.scriptamat.2019.10.032

8. Kren A, Delendik M, Machikhin A. Non-destructive evaluation of metal plasticity using a single impact microindentation. *International Journal of Impact Engineering.* 2022;(162):104141

DOI: 10.1016/j.ijimpeng.2021.104141

9. Hackett BL. [et al.]. Advances in the measurement of hardness at high strain rates by nanoindentation. *J Mater Res.* 2023;5(38):1163-77.

DOI: 10.1557/s43578-023-00921-1

10. Крень А.П. Контроль физико-механических характеристик чугуна прибором ифмх-ч / А.П. Крень [и др.] // *Литьё и металлургия.* – 2019. – № 3.

10. Kren AP. [et al.]. Testing physical and mechanical properties of cast iron using ifmh-ch device. *Casting and metallurgy.* 2019;(3). (In Russ.).

11. Organek P, Gosowski B, Redecki M. Relationship between Brinell hardness and the strength of structural steels. *Structures.* 2024;59:105701.

DOI: 10.1016/j.istruc.2023.105701

12. Антонов А.В. Построение непараметрической плотности распределения на основании цензурированной информации / А.В. Антонов, В.А. Чепурко // *Надёжность.* – М.: Издательский дом «Технология». – 2005. – № 2. – С. 3.

12. Antonov AV, Chepurko VA. Building non-parametric distribution density using censored information. *Reliability.* 2005;(2):3 p. (In Russ.).

13. Hoffman J. *Categorical and Cross-Classified Data: McNemar's and Bowker's Tests, Kolmogorov-Smirnov Tests, Concordance. Basic Biostatistics for Medical and Biomedical Practitioners (Second Edition).* 2019:233-247 pp.

DOI: 10.1016/B978-0-12-817084-7.00015-2