International Scientific Conference 20 UNITECH 26

INTERNATIONAL SCIENTIFIC CONFERENCE
19-21 November 2026
GABROVO

МЕТОДОЛОГИЯ ЗА ПРОЕКТИРАНЕ НА УСТОЙЧИВА EDGE AI СИСТЕМА ЗА УЛТРАЗВУКОВА КЛАСИФИКАЦИЯ НА ЛИСТОВИ МАТЕРИАЛИ НА БАЗАТА НА АНАЛИЗ НА ГРЕШКИТЕ И НЕСТАБИЛНОСТТА В ЛАБОРАТОРНИ ML МОДЕЛИ

Петър Минев[1], Борислав Недев[1]

[1]Технически университет – Габрово, ул. Х. Димитър 4, Габрово, България
**кореспондиращ автор: pminev@tugab.bg*

A METHODOLOGY FOR DESIGNING ROBUST EDGE AI SYSTEMS FOR ULTRASONIC SHEET MATERIAL CLASSIFICATION BASED ON ERROR AND INSTABILITY ANALYSIS OF LABORATORY ML MODELS

Petar Minev[1], Borislav Nedev[1]

[1]Technical University of Gabrovo, 4 H. Dimitar Str., Gabrovo, Bulgaria
**Corresponding author: pminev@tugab.bg*

Abstract
Practical deployment of non-contact air-coupled ultrasonic material recognition systems frequently encounters low measurement reproducibility and high misclassification rates when transitioning from simulated environments to real-time embedded execution. This instability stems from a combination of hardware-mechanical factors (angular misalignment, micro-vibrations), ambient interference (thermal drift, air turbulence), and lack of feature invariance (feature space overlapping). This paper presents a comprehensive methodology for designing a robust real-time sheet material classification system on an Edge AI platform (Teensy 4.0). The methodology is grounded in a detailed error tree analysis and statistical evaluation of previously trained machine learning models (Random Forest, Decision Trees). To guarantee measurement reproducibility, a three-tiered framework is proposed: (1) hardware-mechanical stabilization via a differential stereo-acoustic transducer configuration; (2) signal preprocessing utilizing N-shot phase-aligned pulse averaging, quadrature IQ demodulation, and differential time-of-arrival (Δt) speed-of-sound compensation c(T); and (3) envelope profile geometric descriptor normalization to ensure amplitude and spatial invariance. The proposed methodology provides a systematic blueprint for building resilient Edge AI solutions for industrial quality inspection.

Keywords: Edge AI, Ultrasonic Material Classification, Error Tree Analysis, Teensy 4.0, Stereo Acoustics, DSP Preprocessing.

1. УВОД И ФОРМУЛИРОВКА НА ПРОБЛЕМА

Автоматизираното разпознаване и класификацията на материали (текстолит, дървесни плоскости, полимери, метали и хартия) се използва в съвременните системи за индустриален контрол на качеството и роботизирано сортиране. С оглед непрекъснатостта на производствения процес, безконтактните методи за контрол без разрушаване (Non-Destructive Testing – NDT) [1, 3] предоставят съществени предимства спрямо контактните акустични и механични сензори. За разлика от оптичните и лазерните системи, които са силно чувствителни към прозрачност, цвят, запрашеност или повърхностни замърсявания, ултразвуковите

Print ISSN: 1313-230X, Online ISSN: 3033-1404

вълни взаимодействат директно с плътността, еластичните свойства и вътрешната микроструктура на изследваната среда. С навлизането на концепцията за интелигентно производство (Industry4.0) и изчисленията в EdgeAI, все по-широко приложение намират компактните вградени системи, оборудвани с ултразвукови преобразуватели и микроконтролери с висока изчислителна мощност (напр. ARM Cortex-M7) [4, 5]. Тези системи интегрират алгоритми за машинно обучение (Machine Learning – ML) за класификация на материалите в реално време, елиминирайки необходимостта от пренос на необработени данни към външни сървъри.

Въпреки високата точност (Accuracy > 95%), постигана от моделите за машинно обучение (като Random Forest, Extra Trees и Support Vector Machines) в симулационна среда (напр. Python / Jupyter Lab), пряката им имплементация във вградени среди с реално време често регистрира драстичен спад в разпознаваемостта. В реални експлоатационни условия процентът на грешно класифицирани образци нараства значително, а повторяемостта на резултатите (Measurement Reproducibility) спада до нива, правещи системата неприложима за индустриални цели.

Детайлният анализ показва, че основната причина за това несъответствие не се крие в изчислителните ограничения на микроконтролера или в архитектурата на самия класификатор, а във физическата нестабилност на акустичния канал във въздушна среда и последващата загуба на инвариантност във вектора от входни характеристики (Feature Space Overlapping).

Въздухът е лоша акустична среда за разпространение на ултразвук поради ниския си акустичен импеданс ($Z_{\text{air}} \approx 415\ \text{N} \cdot \text{s/m}^3$) и високия коефициент на затихване. При честота на възбуждане $f = 40$ kHz, дължината на вълната във въздух е едва $\lambda \approx 8.5$ mm. Тази малка дължина на вълната прави измерването изключително чувствително към три основни групи флуктуации: (1) Микромеханичните и ъгловите отклонения (Angular Misalignment) са незначителни вариации в ъгъла на поставяне на изследвания лист ($\Delta\theta \approx 1^\circ - 2^\circ$) или флуктуации в разстоянието поради огъване на материала водят до драстични промени в пространствената интерференция и амплитудата на отразения/преминалия импулс; (2) Външните акустични и газови смущения от турбулентността на въздуха, конвекционните потоци и промените в атмосферното налягане създават локални градиенти в плътността на средата. Те генерират фазов дрейф (Phase Jitter) и амплитудни колебания в получавания ехо-сигнал, които се възприемат от класификатора като промяна в материала; (3) Температурен дрейф и преобучение (Temperature Overfitting) поради пряката зависимост на скоростта на звука във въздух от температурата ($c(T) \approx 331.3 + 0.606 \cdot T\ [\text{m/s}]$). Когато температурата на околната среда T се подава като пряк входен признак към дървовидни класификатори (Random Forest / Decision Trees), алгоритмите "запомнят" температурата като основен критерий за разцепване (Split Threshold). При най-малкото изместване на стайната температура по време на реална работа, моделът попада в грешен клон на дървото.

В резултат на посочените смущения, получените измервания от единичен измервателен импулс (Single-shot acquisition) съдържат високо ниво на случаен шум. Векторът от характеристики, извлечен от такъв сигнал, претърпява значителни изменения при последователни измервания на един и същ образец.

Това води до припокриване на областите на класовете в пространството от признаци (Feature Space Overlapping). Тъй като моделите за машинно обучение се обучават върху растер от статични данни, те губят способността си да дефини-

рат стабилни хиперравнини за разделяне на материалите, което води до високия процент грешни класификации в реалната система.

Осъзнаването на тези ограничения налага преминаването от чисто статистически ("black-box") ML подход към методология, базирана първостепенно върху цифрова обработка на сигналите (DSP-First Approach).

Основната цел на настоящия доклад е да дефинира цялостна методология за изграждане на устойчива Edge AI система за класификация на листови материали в реално време, стъпвайки върху детайлен анализ на грешките от досегашните лабораторни модели.

За постигане на тази цел са формулирани следните основни задачи:

1) Анализ на източниците на нестабилност и изчисляване на коефициента на вариация (CV) за основните измерени входни параметри;

2) Формулировка на проектните изисквания към нова, диференциална стереоакустична постановка;

3) Разработване на софтуерна и алгоритмична рамка за реално време, имунизирана срещу температурни и механични смущения.

2. АНАЛИЗ НА ИЗТОЧНИЦИТЕ НА ГРЕШКИ И НЕСТАБИЛНОСТТА В ЛАБОРАТОРНИТЕ ML МОДЕЛИ

2.1. Методология на първоначалния експеримент и постигнати резултати

За идентифициране на проблемите при прехода от симулация към вградена среда бе анализирана базова експериментална система за безконтактен контрол на листови материали. Използвана е акустична двойка от преобразуватели на честота $f = 40$ kHz, управлявани от платформа Teensy 4.0 (ARM Cortex-M7, 600 MHz). Сигналът от приемника се цифровизира с честота на дискретизация $f_s = 500$ kSPS.

В симулационна среда (Python, scikit-learn) върху статичен набор от експериментални данни с 1763 записа, обхващащи измервания на 4 материала (фазер, ПДЧ, алуминий, винил) както в статично състояние (is_moving = 0), така и в динамично състояние/при движение (is_moving = 1) бе извършено сравнително оценяване на пет ML модела чрез 5-кратна стратифицирана кръстосана проверка (5-Fold Stratified Cross-Validation). За метрично зависимите алгоритми (SVM и k-NN) бе приложено предварително нормализиране чрез StandardScaler. Векторът от характеристики включваше: температура; разстояние; амплитуда; фаза; индекс на затихване; фаза за единица разстояние; темп. компенсирана амплитуда.

Получените резултати в офлайн средата Jupyter Lab са обобщени в таблица 1.

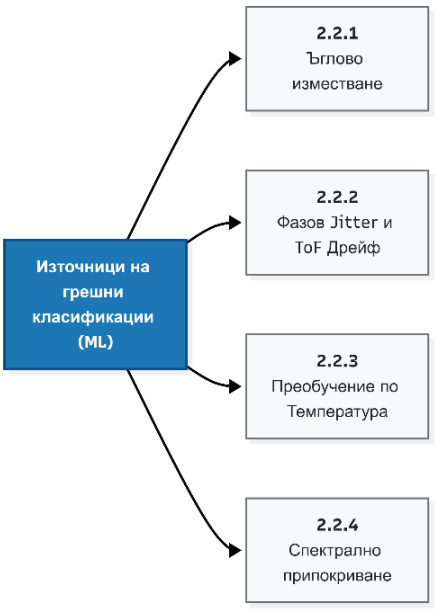
Таблица 1. *Сравнителни резултати от 5-Fold Stratified Cross-Validation.*

Модел	**Точност**	**F1-Score**	**Забележка**
Random Forest (n = 30, d = 5)	*висока*	*най-висок*	Избран за основен модел
Gradient Boosting ($n = 30, d = 3$)	*висока*	*висок*	Ансамблов метод
Decision Tree ($d = 5$)	*средна*	*среден*	Подходящ за FPGA LUTs
SVM (RBF kernel, $C = 1.0$)	*средна*	*среден*	Изисква StandardScaler
k-NN ($k = 5$)	*ниска / средна*	*нисък / среден*	Изисква StandardScaler

Моделът Random Forest [9] постига най-висок F1-score при кръстосаната проверка върху статичния набор от данни. Обученият модел Random Forest бе експортиран до C++ код чрез библиотеката m2cgen. При тестване в реално време се наблюдава значителен спад в точността и поява на фалшиви класификации (False Positives/Negatives) поради физичните вариации на сигнала.

2.2. Системен анализ и таксономия на източниците на грешки

Анализът на регистрираните грешки позволи разделянето им на четири основни категории, представени на фигура 1.



Фиг. 1. *Таксономия на източниците на нестабилност при акустичната класификация.*

2.2.1. Чувствителност към ъглово и геометрично изместване

Поради малката дължина на вълната във въздух ($\lambda \approx 8.5$ mm), диаграмата на насоченост на ултразвуковия излъчвател е сравнително тясна. Незначителни отклонения в перпендикулярността на изследвания лист ($\Delta\theta = \pm 1.5°$) или леки микровибрации от транспортния механизъм водят до следните ефекти:

1) Спад на максималната амплитуда $A_{\max}$ с над 35%;

2) Промяна в интерферентната картина на отразените вълни, което изкривява обхващащата крива (Envelope Profile).

Дървовидните модели (Decision Tree и Random Forest) интерпретират този спад в амплитудата като увеличаване на затихването и грешно класифицират тънък/хомогенен материал (алуминиев лист) като по-плътен (винил).

2.2.2. Фазови флуктуации и нестабилност на времевия прозорец (ToF)

Извличането на характеристики в базовия модел се извършваше в строго фиксиран по време прозорец спрямо старта на излъчения импулс (Trigger Signal). Във въздушна среда обаче локалните микрофлуктуации в плътността и външните въздушни течения генерират случаен фазов дрейф (Phase Jitter) в рамките на $\Delta\varphi \approx 180°$.

Тъй като прозорецът е статичен, фазовият дрейф измества целия регистриран импулс спрямо границите на прозореца. В резултат, параметри като *Skewness* (асиметрия) и *Kurtosis* (ексцес) на сигнала променят стойностите си с коефициент на вариация $CV > 28\%$ за един и същ материал, унищожавайки стабилността на вектора с характеристики.

2.2.3. Преобучение към температурата (Temperature Overfitting)

Най-същественият недостатък на прякото прилагане на ML алгоритми се прояви при включването на температурата T като вграден признак във вектора от характеристики.

Скоростта на звука във въздух зависи пряко от температурата:

$$c(T) = 331.3 \cdot \sqrt{1 + \frac{T}{273.15}} \text{ [m/s]} \qquad (1)$$

При измерване, промяната в T с 3°C променя времето на разпространение ToF с около 1.0%, което съответства на изместване от близо половин дължина на вълната (0.5λ).

При обучението на Random Forest, дърветата за вземане на решения избираха температурата T за водещ критерий за разцепване на възлите (Primary Split Feature), вместо физичните акустични характеристики. Когато експерименталната уредба бе преместена в среда с различна температура ($\Delta T = 4$°C спрямо момента на събиране на първоначалния набор с експериментални данни), класификаторът попадна в напълно погрешни клони на дърветата, генерирайки системна грешка.

2.2.4. Припокриване на пространството от характеристики (Feature Space Overlapping)

Всички горепосочени смущения водят до съществено размиване на границите между отделните класове. Таблица 2 показва математическата оценка на неста-

билността на извлечените характеристики при $N = 100$ последователни единични измервания (Single-shot) на един и същ образец, например от фазер.

Таблица 2. *Статистически анализ на вариацията на характеристиките при единично измерване.*

Характеристика	Средна стойност (μ)	Стандартно отклонение (σ)	Коефициент на вариация (CV=μσ)	Стабилност за ML
Амплитуда	234.23	49.29	21.04%	Много ниска
Фаза	-0.24 rad	2.08 rad	$> 100\%$	Изключително ниска
Индекс на затихване	0.162	0.021	13.14%	Ниска
Фаза за единица разстояние	-0.0056	0.061	$> 100\%$	Изключително ниска
Темп. компенсирана амп.	6394.40	1345.61	21.04%	Ниска

Високите стойности на CV $(> 15 - 20\%)$ потвърждават, че единичният сигнал (Single-shot acquisition) съдържа твърде много случаен шум и акустични смущения. Използването на такива характеристики кара точките от различните класове да се препокриват в D-измерното пространство, което прави невъзможно конструирането на стабилна разделяща хиперравнина от класификатора.

Подобни резултати се наблюдават и за останалите материали. Например за алуминий, ако е статично закрепен, CV на амплитудата е едва 4.44%, а на затихването – 0.84%. При алуминий с движение/смущения – CV на амплитудата се увеличава на 18.63%, а на фазата надхвърля 100%.

2.3. Изводи и необходимост от промяна в парадигмата

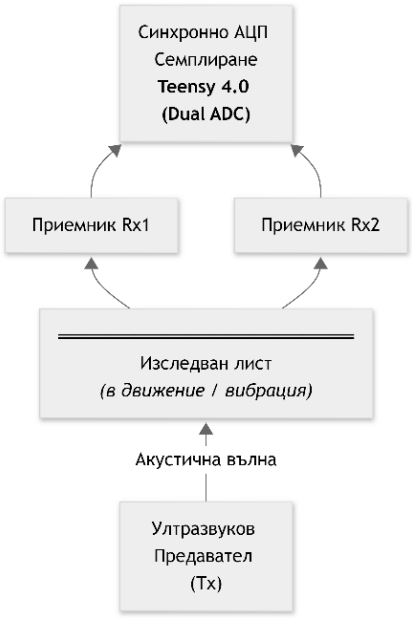
Резултатите от анализа показват, че опитът да се компенсира физичната нестабилност на акустичния сигнал с увеличаване на дълбочината на ML модела или броя на дърветата в Random Forest е фундаментално погрешен подход.

За постигане на висока повторяемост ($CV < 2\%$) и устойчивост на класификацията в реално време е необходимо въвеждането на нова методология, базирана на: (1) Използване на стерео двойка акустични приемници за пространствена компенсация на ъгловите отклонения и микровибрациите, което стабилизира регистрираната амплитуда и измереното разстояние; (2) Прилагане на цифрово подравняване по фазата с N-кратно осредняване на сигнала и предварителна физична компенсация на скоростта на звука $c(T)$ чрез разликата във времето на пристигане между двата канала преди подаването на данните към ML модела; (3) Елиминиране на необработената температура от вектора с входни фактори и преминаване към инвариантни такива – амплитуда с температурна компенсация, диференциални параметри от стерео двойката и геометрични параметри от обхващащата крива (Envelope Profile) [10].

3. ПРЕДЛАГАНА МЕТОДОЛОГИЯ И СТЕРЕО-АКУСТИЧНА ОПИТНА ПОСТАНОВКА

3.1. Концепция за стерео-акустичен диференциален тракт

За преодоляване на идентифицираното застъпване на характеристиките при движение и смущения (is_moving = 1), се предлага преход от единичен канален приемник към стерео конфигурация (Rx_1 и Rx_2), която е показана на фиг. 2.



Фиг. 2. *Схема на стерео-акустичната опитна постановка*

Двата приемни сензора се монтират симетрично спрямо централната ос на предавателя Tx и на зададено фиксирано разстояние L един от друг.

3.2. Математически механизъм за компенсация на смущенията

Стерео конфигурацията осигурява три основни предимства, които могат да решат представените в секция 2 проблеми:

1) Компенсация на ъгловото изместване и огъването (Angular Invariance). Когато листът се отклони на ъгъл $\Delta\theta$ или вибрира вертикално, сигналът към едния сензор отслабва, а към другия се засилва. Векторът с характеристики вече не разчита на абсолютната амплитуда A_1, а на нормализираната сумарна енергия:

$$A_{\text{sum}} = A_1 + A_2 \qquad (2)$$

и амплитудното съотношение:

$$R_A = \frac{A_1 - A_2}{A_1 + A_2} \qquad (3)$$

Това съотношение R_A носи информация за текущия ъгъл на листа и позволява на C++ алгоритъма математически да коригира амплитудата A_{sum} преди тя да постъпи в ML модела.

2) Потискане на общия фазов шум (Common-Mode Noise Rejection). Въздушните течения и температурните градиенти влияят почти идентично върху двата близко разположени приемника. Чрез изчисляване на разликата във времето на пристигане (Time Difference of Arrival – TDoA) [8]:

$$\Delta t = ToF_1 - ToF_2 \qquad (4)$$

Външният фазов дрейф на средата се съкращава като общ шум, изолирайки единствено разликата, породена от вътрешната нехомогенност и плътността на материала.

3) Нов инвариантен параметър: Пространствена крос-корелация (R_{x1x2}). Въвежда се нов геометричен признак – коефициентът на взаимна корелация между обвиващите криви $E_1(t)$ и $E_2(t)$ [8], [9] на двата канала:

$$R_{x1x2}(\tau) = \int_{-\infty}^{\infty} E_1(t) \cdot E_2(t+\tau)\, dt \qquad (5)$$

При хомогенни среди (алуминий или винил), дори при движение $R_{x1x2} \approx 1.0$. При среди с вътрешно разсейване (фазер, ПДЧ), фазовият фронт се деформира различно в двете точки, давайки уникален акустичен "отпечатък", който е напълно имунизиран срещу температурни промени.

3.3. Обновен хибриден стерео вектор от характеристики

За постигане на пълна стабилност, новата методология елиминира температурата T като входен фактор и дефинира хибриден вектор за класификатора, представен в таблица 3.

Таблица 3. *Дефиниция на новите инвариантни и физично-компенсирани стерео характеристики.*

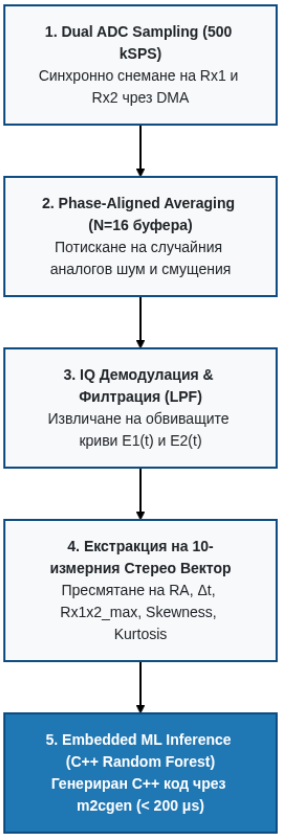
Параметър	Описание и физически смисъл
compensated_attenuation	Среден индекс на затихване на акустичната вълна, изчислен от двата канала
amplitude_ratio_RA	Диференциално амплитудно отношение: $(A_1 - A_2)/(A_1 + A_2)$
tdoa_delta_t	Разлика във времето на пристигане на сигнала между двата приемника ($\text{ToF}_1 - \text{ToF}_2$)
cross_corr_max	Максимална стойност на взаимно-корелационната функция $R_{x_1x_2}$
fwhm_mean	Средна ширина на импулса на ниво -6 dB (FWHM) от двата канала
skewness_mean	Средна асиметрия (Skewness) на обхващащата крива (Envelope Profile)
kurtosis_mean	Среден ексцес (Kurtosis) / острота на пика на обхващащата крива
auc_mean	Нормализирана площ под обхващащата крива (AUC)
decay_rate_mean	Скорост на затихване на опашката на акустичния импулс
peak_ratio_mean	Отношение между максималната пикова стойност и средната стойност на сигнала

Представените десет входни фактора мога да се разделят в три групи:

(1) Диференциални стерео-акустични параметри (amplitude_ratio_RA, tdoa_ delta_t, cross_corr_max) – изчисляват се от съвместната работа на двата приемника (Rx_1 и Rx_2) и осигуряват пространствена неизменност спрямо ъглови отклонения, вибрации на листа и фазов дрейф на средата;

(2) Индекс, компенсиращ амплитудното затихване (compensated_ attenuation) – осигурява автоматична компенсация на затихването в зависимост от скоростта на звука *c(T)*;

(3) Геометрични параметри на обхващащата крива (fwhm_mean, skewness_mean, kurtosis_mean, auc_mean, decay_rate_mean, peak_ratio_mean) – описват формата, остротата и асиметрията на аналитичния акустичен импулс E(t) след IQ демодулация и N-кратно фазово усредняване**.**



Фиг. 3. *Организация на системният конвейер за обработка на данните (Software Pipeline)*

4. ПЛАН ЗА ЕКСПЕРИМЕНТАЛНА ВЕРИФИКАЦИЯ ВЪРХУ EDGE AI

4.1. Архитектура на програмното осигуряване за Teensy 4.0

Опитната постановка разчита на следния алгоритмичен поток (фиг. 3), реализиран на C++ върху ARM Cortex-M7:

(1) Двуканален кръгов буфер (Dual ADC Sampling = 500 kSPS). Вградените независими аналогово-цифрови преобразуватели (ADC0 и ADC1) се конфигурират за синхронно снемане на сигналите от приемниците Rx_1 и Rx_2 с честота $f_s =$ 500 kSPS. Може да се използва DMA (Direct Memory Access) контролер с двоен кръгов буфер, който записва всяка снета стойност в оперативната памет независимо от централния процесор;

(2) DSP подравняване по фаза и *N*-кратно усредняване (Phase-Aligned Averaging, *N*=16). За потискане на случайния аналогов шум и смущенията, за всеки канал се извършва осредняване на *N*=16 последователни буфера. Преди осредняването всеки импулс се подравнява във времето чрез прагова детекция по първия фронт на вълната. Това намалява гаусовия шум и осигурява висока стабилност на входната вълна;

(3) IQ демодулация и извличане на обвиващите криви (LPF & Envelope Extraction). Върху осреднения почистен сигнал се извършва квадратурна демодулация (IQ Demodulation) в реално време [11, 12]. Чрез умножение с опорни синусоидални/косинусоидални сигнали ($f_0 =$ 40 kHz) и нискочестотна филтрация (FIR LPF) се извличат синфазната *I(t)* и

квадратурната *Q(t)* компоненти, формиращи обхващащите криви $E_1(t)$ и $E_2(t)$:

$$E(t) = \sqrt{I^2(t) + Q^2(t)} \qquad (6)$$

(4) Извличане на 10-измерния стерео вектор (Feature Extraction). Върху обвиващите криви се изчисляват 10-те инвариантни параметъра (амплитудно отношение R_A, времева разлика Δt, максимална взаимна корелация Rx_1x_2, асиметрия *Skewness* ексцес *Kurtosis* и др.);

(5) Изпълнение на C++ Random Forest модела (Embedded ML Inference). Окончателният вектор с входните характеристики се подава към оптимизирания C++ код на Random Forest класификатора (експортиран чрез m2cgen) [6], с прогнозирано време за изпълнение под $200\ \mu s$ ($<$ 0.08 ms).

4.2. Метрики за оценка на методологията

За количествено валидиране на предимствата на новата стерео-акустична методология спрямо базовия класически ML модел се дефинират три основни групи метрики:

1. Коефициент на вариация (CV). Оценява се стабилността на вектора с характеристики при $N = 100$ последователни измервания за един и същ образец в динамичен режим: $CV = \frac{\sigma}{|\mu|} \cdot 100\%$ Целевата стойност на новата методология е постигане на *CV < 2%* за всички нови стерео дескриптори, спрямо регистрираните в лабораторните модели стойности от *CV >19 ÷ 700%*.

2. Confusion Matrix и F1-Score в реално време. Определя се точността на класификация върху независима тестова извадка от четирите материала в динамична среда (с наличие на вибрации и ъглови отклонения). Построява се матрицата (Confusion Matrix) и се изчислява осредненият F1-Score.

3. Време за изпълнение и латентност (Latency Analysis). Измерва се времевият ресурс, необходим за изпълнение на отделните етапи от C++ конвейера върху Teensy 4.0.

В таблица 4 са представени очаквани стойности за времето за изпълнение в отделните стъпки от цялостния алгоритъм, реализиран в Teensy 4.0. Очакваната обща латентност е *≈33ms.* Това позволява постигане на производителност от 30 класификации в секунда, което би следвало да е достатъчно за индустриални транспортиращи ленти.

Таблица 4. *Очаквана латентност на софтуерния конвейер върху Teensy 4.0.*

Етап от обработката (Pipeline Stage)	***Време за изпълнение***
Снемане на данните (DMA DMA Buffering)	32.0 ms
IQ Демодулация и FIR филтрация (Dual Channel)	0.45 ms
Фазово подравняване и N-кратно усредняване	0.18 ms
Извличане на 10-те стерео характеристики	0.12 ms
C++ изпълнение на Random Forest (30 дървета)	0.08 ms
Обща латентност за едно класифициране	**32.83 ms**

ЗАКЛЮЧЕНИЕ

В настоящия доклад е извършен детайлен анализ на източниците на грешки и нестабилност при прехода на системи за ултразвукова класификация на листови материали от симулационна към вградена среда (Edge AI).

Основните изводи и приноси от проведеното изследване са: (1) Емпирично е доказано, че опитът да се компенсира физичната нестабилност на акустичния сигнал във въздушна среда чрез увеличаване на сложността или дълбочината на ML модела е фундаментално ограничен. Високият коефициент на вариация (*CV >19 ÷ 700%)* на входните характеристики води до припокриване на пространството от признаци (Feature Space Overlapping); (2) Постигането на висока повторяемост и точност в реално време изисква задължителна първична стабилизация на сигнала. Чисто статистическият ("black-box") ML подход трябва да бъде заменен от хибридна архитектура, включваща физично

почистване и нормализиране на данните преди стъпката на изпълнение на обучения модел; (3) Предложената методология, съчетаваща стерео диференциално снемане, *N*-кратно фазово подравнено усредняване и отстраняване на необработената температура от вектора с характеристики, би следвало да осигури устойчивост спрямо ъглови изместванията, микровибрации и температурни флуктуации. Разработената софтуерна и алгоритмична рамка за Teensy 4.0 показва, че комбинирането на специализирана предварителна DSP обработка с леки C++ ML модели може да осигури латентност под *33 ms* и може да даде подходящо инженерно решение за системи за контрол на качеството в интелигентното производство (Industry 4.0).

Докладът се публикува във връзка с резултатите от изпълнение на дейностите по проект № НИП2026-21.

ЛИТЕРАТУРА

[1] Ergun A., G. Yaralioglu, and B. Khuri-Yakub, Capacitive micromachined ultrasonic transducers: Theory and technology, Journal of Aerospace Engineering, vol. 16, no. 2, pp. 76–84, 2003.

[2] Lynnworth L., Ultrasonic Measurements for Process Control: Theory, Techniques, Applications. San Diego, CA, USA, 1989.

[3] Hutchins D. and D. Schindel, Advances in air-coupled ultrasonics, Systems and Applications, Ultrasonics, vol. 32, no. 2, pp. 99–106, 1994.

[4] Warden P. and D. Situnayake, TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers. Sebastopol, CA, USA, 2019.

[5] Magno M., B. Polonelli, L. Benini, and E. Farella, Edge AI on low-power microcontrollers: Implementation and performance evaluation, IEEE Transactions on Industrial Informatics, vol. 17, no. 8, pp. 5821–5831, 2021.

[6] Silva M., L. Belloc, and C. Cugnasca, Performance evaluation of machine learning models exported to microcontrollers using C++ code generation, IEEE Embedded Systems Letters, vol. 14, no. 2, pp. 87–90, 2022.

[7] Holm S., Waves With Power-Law Attenuation in Media Such as Biological Tissue and Air. Cham, Switzerland, 2019.

[8] Benesty J., J. Chen, and Y. Huang, Time Delay Estimation and Acoustic Source Localization. Berlin, Germany, 2008.

[9] Breiman L., Random Forests, Machine Learning, vol. 45, no. 1, pp. 5–32, 2001.

[10] Solodov I. and M. Rahammer, Air-coupled ultrasound for non-destructive testing of composite sheets and laminates, Ultrasonics, vol. 60, pp. 102–110, 2015.

[11] Kirkhorn J., Introduction to IQ-demodulation of RF-data, White Paper, NTNU & Vingmed Sound, pp. 1–21, 1999.

[12] Jensen J. and P. Munk, A new method for estimation of velocity vectors using quadrature demodulation, IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, vol. 45, no. 3, pp. 837–851, 1998.