

інформаційно-вимірювальних систем, що працюють у режимі реального часу та взаємодіють із хмарними платформами.

Проблема, що розглядається в цьому дослідженні, полягає у створенні доступної, надійної та енергоефективної системи моніторингу параметрів житлового приміщення з можливістю дистанційного керування. Актуальність теми визначається зростанням потреби у підвищенні безпеки, комфорту та ефективності використання ресурсів у житлових будівлях. Мета дослідження полягає в розробці методів та засобів побудови IoT-орієнтованої інформаційно-вимірювальної системи, що базується на доступних мікроконтролерних технологіях та здатна забезпечити комплексний контроль параметрів розумного будинку.

Запропонована система складається з низки апаратних і програмних компонентів, інтегрованих у єдину IoT-архітектуру. Центральним елементом виступає мікроконтролерний Wi-Fi модуль NodeMCU, який забезпечує збирання даних, локальну обробку та бездротову передачу інформації у хмару. Для вимірювання освітленості застосовано цифровий давач BH1750FVI, що забезпечує високу точність і швидкість зчитування рівня освітлення. Контроль температури й вологості виконується за допомогою давача DHT22. Виявлення диму та горючих газів здійснюється модулем MQ-2, що підвищує рівень безпеки житлового приміщення. Для локального відображення зібраних даних використовується OLED-дисплей, що дозволяє оперативно переглядати параметри системи без доступу до Інтернету.

Хмарна взаємодія реалізована на базі Arduino Cloud, що забезпечує збирання, візуалізацію та збереження даних, а також дистанційне керування виконавчими пристроями. Логіка роботи програми мікроконтролера передбачає циклічне зчитування параметрів, їх первинну фільтрацію, передачу до хмари та отримання команд користувача. У разі виявлення критичних значень система може виконувати локальні аварійні функції, наприклад запуск вентиляції чи подачу сигналізації. Комунікація з Arduino Cloud забезпечує можливість віддаленого контролю з будь-якої точки світу.

Перевагами запропонованої системи є її модульність, низька вартість, доступність компонентів, простота інтеграції та масштабованість. Завдяки використанню хмарної платформи забезпечено високий рівень зручності для користувача, а вибір малопотужних сенсорів і мікроконтролера сприяє енергоефективності.

Розроблена IoT-орієнтована інформаційно-вимірювальна система є ефективним рішенням для моніторингу та управління параметрами розумного будинку. Система забезпечує збір широкого спектра даних, інтеграцію з хмарними сервісами та можливість дистанційного керування у режимі реального часу.

УДК 57.087.1

Ю.Б. Паляниця, к.т.н.; М.Ю. Ковальчук

(Тернопільський національний технічний університет імені Івана Пулюя, Україна)

МЕТОД ІНТЕЛЕКТУАЛЬНОЇ КЛАСИФІКАЦІЇ ЛІТАЮЧИХ ОБ'ЄКТІВ ЗА ЇХ АКУСТИЧНИМИ СИГНАТУРАМИ

Y.B. Palianytsia PhD, M.Y. Kovalchuk

METHOD OF INTELLIGENT CLASSIFICATION OF FLYING OBJECTS BY THEIR ACOUSTIC SIGNATURES

Акустична класифікація літаючих об'єктів є актуальною задачею у контексті систем моніторингу повітряного простору. Основна мета дослідження полягає у

розробці ефективного методу розпізнавання типу літального апарату за його звуковою сигнатурою з використанням інтелектуальних алгоритмів. Звуковий сигнал літаючого об'єкта формується комбінацією гармонік від двигунів, резонансів корпусу та аеродинамічного шуму, що створює унікальний акустичний відбиток кожного класу об'єктів.

Звуковий сигнал описується функцією $x(t)$, що представляє зміну амплітуди акустичного тиску у часі. Основними характеристиками є амплітуда A , частота f , фаза ϕ та тривалість T . Дискретизований сигнал представляється як $x[n] = x(nT_s)$, де $T_s = 1/f_s$ - період дискретизації, f_s - частота дискретизації. Енергія сигналу визначається як

$$E = \sum_{n=1}^N |x[n]|^2, \text{ а середня потужність як } P = \frac{1}{N} \sum_{n=1}^N |x[n]|^2.$$

Важливим етапом, що передуює класифікації є попередня обробка сигналів [1,2], зокрема нормалізація сигналу здійснюється за формулою $\tilde{x}[n] = \frac{x[n] - \mu}{\sigma}$, де

$$\mu = \frac{1}{N} \sum_{n=1}^N x[n] - \text{середнє значення, } \sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (x[n] - \mu)^2} - \text{стандартне відхилення.}$$

Фільтрація шуму реалізується через смуговий фільтр з передатною функцією $H(f) = \begin{cases} 1, & f_1 \leq f \leq f_2 \\ 0, & \text{інакше} \end{cases}$, де $[f_1, f_2]$ - діапазон робочих частот. Для адаптивного шумозаглушення використовується фільтр Вінера $W(f) = \frac{S_{xx}(f)}{S_{xx}(f) + S_{nn}(f)}$,

де $S_{xx}(f)$ - спектральна щільність сигналу, $S_{nn}(f)$ - спектральна щільність шуму.

Часові ознаки включають короткочасну енергію [3] $E_k = \sum_{n=kH}^{kH+W-1} x^2[n]$, швидкість перетину нуля $ZCR_k = \frac{1}{2W} \sum_{n=kH}^{kH+W-1} |\text{sgn}(x[n]) - \text{sgn}(x[n-1])|$, де W - розмір вікна,

H - крок зсуву. Частотні характеристики отримуються через перетворення Фур'є $X(k) = \sum_{n=0}^{N-1} x[n] e^{-j2\pi kn/N}$, спектральний центроїд $SC = \frac{\sum_{k=1}^K f_k |X(k)|}{\sum_{k=1}^K |X(k)|}$ та спектральний

$$\text{розкид } SS = \sqrt{\frac{\sum_{k=1}^K (f_k - SC)^2 |X(k)|}{\sum_{k=1}^K |X(k)|}}.$$

Методи на основі спектрального аналізу включають швидке перетворення Фур'є, яке реалізується за алгоритмом $X[k] = \sum_{n=0}^{N-1} x[n] W_N^{kn}$, де $W_N = e^{-j2\pi/N}$, з обчислювальною складністю $O(N \log N)$. Спектрограма формується через короткочасне перетворення Фур'є $S(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) w(\tau - t) e^{-j2\pi f \tau} d\tau \right|^2$, де $w(t)$ - віконна функція Хеммінга $w[n] = 0.54 - 0.46 \cos(2\pi n/N)$.

Вейвлет-аналіз базується на перетворенні $W(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt$, де $\psi(t)$ - материнський вейвлет, a - параметр масштабу, b - параметр зсуву. Вейвлет Морле визначається як $\psi(t) = \frac{1}{\sqrt[4]{\pi}} e^{j\omega_0 t} e^{-t^2/2}$, що забезпечує оптимальну локалізацію у часі та частоті.

Мел-кепстральні коефіцієнти обчислюються через послідовність перетворень: дискретне перетворення Фур'є, застосування мел-фільтрів $M(f) = 2595 \log_{10}(1 + f/700)$, логарифмування енергій та дискретне косинусне перетворення $MFCC[m] = \sum_{k=1}^K \log(E_k) \cos\left[m(k - 0.5) \frac{\pi}{K}\right]$, де E_k - енергія в k -му мел-каналі, $m = 1, 2, \dots, M$ - номер коефіцієнта.

До статистичних методів відносимо кореляційний аналіз оцінює схожість двох сигналів через функцію взаємної кореляції $R_{xy}(\tau) = \int_{-\infty}^{\infty} x(t) y(t + \tau) dt$, у дискретній формі $R_{xy}[m] = \sum_{n=0}^{N-1} x[n] y[n + m]$. Автокореляційна функція

$R_{xx}(\tau) = \int_{-\infty}^{\infty} x(t)x(t+\tau)dt$ визначає періодичність сигналу та використовується для детектування основної частоти. Коефіцієнт кореляції Пірсона $\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$ кількісно оцінює лінійний зв'язок між сигналами.

Методи на основі шаблонного співставлення включають алгоритм динамічного розтягування DTW, що мінімізує відстань між двома послідовностями через матрицю накопичених відстаней $D(i, j) = d(x_i, y_j) + \min\{D(i-1, j), D(i, j-1), D(i-1, j-1)\}$, де $d(x_i, y_j) = |x_i - y_j|$ - локальна відстань. Оптимальний шлях знаходиться через зворотний прохід матриці D . Еталонна бібліотека формується з набору $\{T_1, T_2, \dots, T_C\}$ шаблонів для C класів, класифікація виконується за принципом $\hat{c} = \operatorname{argmin}_c DTW(x, T_c)$.

Методи розпізнавання на основі машинного навчання є найбільш сучасними [4], до яких входить багат шарова нейронна мережа яка реалізує відображення $f: \mathbb{R}^d \rightarrow \mathbb{R}^C$ через послідовність перетворень $h^{(l)} = \sigma(W^{(l)}h^{(l-1)} + b^{(l)})$, де $\sigma(z) = \frac{1}{1+e^{-z}}$ - сигмоїдна функція активації, $W^{(l)}$ - матриця ваг, $b^{(l)}$ - вектор зміщень. Функція втрат для задачі класифікації $L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{ic} \log(\hat{y}_{ic})$, де y_{ic} - істинна мітка, $\hat{y}_{ic}$ - передбачення.

Також в роботі нами використано згорткову нейронну мережу, яка показала найвищу точність класифікації 92%, вона виконує операцію згортки $(x * w)[n] = \sum_{m=-M}^M x[n-m]w[m]$, пулінгу $p[n] = \max_{k \in R_n} h[k]$ та повнозв'язних шарів.

Рекурентна ж мережа LSTM оперує з послідовностями через вентиля забування $f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$, входу $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$, виходу $o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$ та стан $c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$ комірки.

Метод опорних векторів знаходить гіперплощину $w^T x + b = 0$, що максимізує відстань до найближчих точок через оптимізацію $\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$ за умов $y_i(w^T x_i + b) \geq 1 - \xi_i$. Для нелінійної класифікації використовується ядрова функція $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$, що відображає дані у простір вищої розмірності.

Література

1. Smith, Steven W. (1997). The Scientist and Engineer's Guide to Digital Signal Processing. California Technical Publishing.
2. Proakis, J. G., & Manolakis, D. G. (2006). Digital Signal Processing: Principles, Algorithms, and Applications. Pearson.
3. Паляниця Ю. Б., Сверстюк А. С., Шадріна Г. М. Математичне та комп'ютерне моделювання фонокардіосигналів для удосконалення кардіодіагностичних систем : монографія. Львів : Магнолія-2006, 2020. 106 с. ISBN 5-211-05310-9.