



Enhancement of LMS Adaptive Filter Performance for Military Noise Reduction Using Genetic Algorithm Optimization of Five Signal Features Combination

Nima Jafari¹ , Reza Esfehani^{2*}

¹ Master's degree Imam Hussein University, Tehran, Iran. Email Address: jfrynyma672@gmail.com

²Correspondence: Assistant Professor, Imam Hussein University, Tehran, Iran, Email Address resfahani@ihu.ac.ir

ARTICLE INFO

Article history:

Article Type: Research paper

Received: 16 September 2025

Received in revised form: 29 November 2025

Accepted: 13 July 2026

Available online: 21 August 2026

Keywords:

Adaptive Filter

Noise Cancellation

Military Audio Processing

Dynamic Learning Parameter

SNR

Genetic Algorithm

Coefficient Optimization

ABSTRACT

Audio signal processing in military environments has consistently faced significant challenges due to the presence of complex noises such as explosions, weapon fire, and electromagnetic interference. This study presents an advanced method for removing environmental noise from military audio signals, utilizing a Least Mean Squares (LMS) adaptive filter with a dynamic learning rate. The primary innovation of this research is the simultaneous use of five input signal features—namely, energy, variance, covariance, entropy, and zero-crossing rate—for the automatic adjustment of the learning rate. The optimal combination of these features was achieved using a genetic algorithm with a population of 50 chromosomes over 10 generations, yielding the optimal coefficient set: [0.8486, 0.1872, 0.5016, 0.9195, 0.3582]. Experimental results demonstrate that the proposed method achieves a 12.43 dB improvement in the Signal-to-Noise Ratio (SNR) – from -0.18 dB to 12.25 dB – and reduces the Mean Squared Error (MSE) to 0.0016. Furthermore, the method shows a 1.95 dB superior SNR improvement compared to fixed learning-rate filters and a 1.56-fold reduction in error variance. By maintaining an optimal balance between accuracy and computational complexity, this algorithm is well-suited for critical military applications.

Cite this article: N. Jafari and R. Esfehani, "Enhancement of LMS Adaptive Filter Performance for Military Noise Reduction Using Genetic Algorithm Optimization of Five Signal Features Combination," Journal of Passive Defence, vol. 17, no. 2, pp. 45-58, 2026. DOI: <https://doi.org/10.47176/pd.2026.1576>



OPEN ACCESS

© Author(s) retain the copyright and full publishing rights

Publisher: Imam Hossein University.

Introduction

Audio signal processing in military environments has consistently confronted significant operational and security challenges due to the presence of complex, non-stationary, and high-energy noises such as explosions, gunfire, and electromagnetic interference. These impulsive noises can completely mask the useful signal, thereby compromising the clarity and intelligibility of voice communications that are critical for mission success. The principal objective in this domain is to preserve speech intelligibility under conditions in which conventional signal enhancement methods fail.

Over the past decades, a wide spectrum of noise-cancellation techniques has been developed, ranging from fixed FIR/IIR filters with limited flexibility, to adaptive filters such as the Least Mean Squares (LMS) algorithm with fixed learning-rate parameters, to model-based approaches like the Kalman filter, time-frequency methods such as wavelet transforms, and most recently, deep learning-based solutions. Despite their individual merits, none of these approaches simultaneously satisfies the key requirements of military applications—namely, robust performance in non-stationary noise, fast adaptation, computational lightness, and independence from prior system models or large training datasets.

To address this gap, the present study proposes an innovative self-regulating solution: an LMS adaptive filter with a dynamic learning rate that is intelligently and instantaneously tuned based on an optimized linear combination of five complementary signal features—namely, energy, variance, covariance, entropy, and zero-crossing rate (ZCR). The optimal weighting coefficients for this combination are systematically determined using a Genetic Algorithm (GA), enabling the system to achieve optimal performance in dynamic and unpredictable operational environments without manual tuning or dependence on a predefined noise model.

Research Objectives and Questions

The study seeks to answer the following central question:

How can the performance of LMS adaptive filters in suppressing complex military noise be enhanced through the optimized combination of multiple signal features, and to what extent does this approach outperform conventional fixed-parameter methods in terms of Signal-to-Noise Ratio (SNR) and Mean Squared Error (MSE)?

The specific objectives are:

1. To design and implement an LMS adaptive filter whose learning rate is dynamically adapted to the instantaneous content of the input signal.
2. To extract, on a frame-by-frame basis, five complementary features—energy, variance, covariance, entropy, and ZCR—that collectively characterize the signal–noise state.
3. To optimize the weighting coefficients of these five features using a Genetic Algorithm under a multi-objective fitness function that simultaneously maximizes SNR and minimizes MSE.
4. To evaluate the proposed method across diverse military noise scenarios, including combined impulsive noise, isolated explosions, and white Gaussian noise.
5. To compare the proposed approach quantitatively against fixed-parameter LMS filters, manually-tuned coefficient methods, and benchmark techniques such as Kalman filtering, wavelet transforms, and deep learning.

Methodology

This study follows an applied, quantitative research design focused on the design, simulation, and evaluation of a novel adaptive filtering algorithm. The research was conducted in four main stages:

Stage 1 — Feature Extraction. The noisy input signal was segmented into short overlapping frames, from which five key features were computed in real time: signal energy (Eq. 1), variance (Eq. 2), Shannon entropy (Eq. 3), zero-crossing rate (Eq. 4), and covariance between the signal and its squared

version (Eq. 5). These features were selected based on the hypothesis that their joint dynamics can comprehensively characterize the transient and spectral behavior of military noise.

Stage 2 — Genetic Algorithm Optimization. A Genetic Algorithm was employed to determine the optimal weighting coefficients for combining the five features. A systematic sensitivity analysis (Table 2) was conducted across population sizes (30, 50, 70, 100), generations (5, 10, 15, 20), crossover probabilities (0.6, 0.7, 0.8), and mutation probabilities (0.01, 0.05, 0.1). The selected baseline configuration—population = 50, generations = 10, $P_c = 0.7$, $P_m = 0.05$ —yielded the best trade-off between fitness quality (100%) and computational cost (100 s), with stable convergence observed at generation 7.

Stage 3 — Dynamic LMS Filter Design. A variable-step-size LMS adaptive filter was implemented in which the instantaneous learning rate $\mu(i)$ is computed as a normalized linear combination of the five extracted features using the GA-optimized coefficients (Eq. 9). The fitness function (Eq. 6) was designed as a weighted sum: $0.7 \times \text{SNR}_{\text{output}} - 0.2 \times \text{MSE}$, ensuring simultaneous maximization of output SNR (Eq. 7) and minimization of mean squared error (Eq. 8).

Stage 4 — Performance Evaluation. The system was benchmarked against fixed- μ LMS filters, manually-tuned coefficient methods, and three reference techniques—Kalman filtering, wavelet-based denoising, and deep learning—across three representative noise scenarios (combined gunshot-engine, isolated explosion, and white Gaussian noise).

The reliability of the simulation framework was validated through repeated runs under controlled noise conditions. Computational tools included MATLAB for signal processing and algorithm implementation, with all statistical comparisons performed under identical input conditions.

Findings

The Genetic Algorithm converged to the following optimal coefficient vector for the five features: **[0.8486, 0.1872, 0.5016, 0.9195, 0.3582]**, corresponding to energy, variance, covariance, entropy, and ZCR, respectively. Notably, **entropy** received the highest weight (0.9195), confirming its dominant role in characterizing unpredictable military noise, while **variance** received the lowest weight (0.1872).

The principal performance results are summarized as follows:

- **SNR Improvement:** The proposed method achieved an SNR improvement of **12.43 dB**, elevating output SNR from -0.18 dB to **12.25 dB**.
- **Error Reduction:** Mean Squared Error was reduced to **0.00160**, corresponding to a **1.56-fold reduction in error variance compared to the fixed- μ baseline**.
- **Comparative Superiority over Fixed- μ LMS:** **+1.95 dB in SNR and a 0.00160 vs. 0.00251 MSE**.
- **Comparative Superiority over Manual Coefficients:** **+0.26 dB in SNR and 0.00160 vs. 0.00170 MSE**.

Performance across noise scenarios:

Noise Scenario	SNR Improvement (dB)	MSE ($\times 10^{-4}$)
Combined (Gunshot + Engine)	12.43	16.0
Impulsive (Explosion)	11.80	18.5
White Gaussian	13.20	14.2

Benchmark comparison (Table 7) revealed that while deep learning methods achieve higher raw SNR gains (25–30 dB) and wavelet methods report 18–22 dB, the proposed method delivers a balanced trade-off—achieving robust noise suppression without requiring large training datasets, accurate system models, or excessive computational resources. The time-domain and frequency-domain visualizations (Figures 3–7) confirmed the direct, intelligent correlation between sudden increases in feature values (e.g., during explosions) and the automatic rise in the dynamic learning rate, validating the adaptive control mechanism.

Discussion

The findings confirm that the intelligent fusion of five complementary signal features within a GA-optimized linear weighting framework substantially enhances LMS filter performance in complex military noise environments. The dominance of entropy (0.9195) in the optimal coefficient set suggests that unpredictability and information complexity are the most discriminative indicators of military noise, justifying the prioritization of entropy-based metrics in adaptive filter design.

A central contribution of this work lies in the **balanced trade-off** it offers: although deep learning can deliver superior raw SNR improvements in ideal conditions, such methods depend on massive labeled datasets and substantial computational infrastructure—resources often unavailable in field-deployed military systems. Similarly, wavelet and Kalman approaches, while effective in specific contexts, suffer from base-sensitivity, distortion risks, or stringent linear-model assumptions. The proposed method avoids these dependencies by leveraging a lightweight, self-optimizing architecture that can be retrained online with minimal data.

However, this balanced intelligence is not without cost. The simultaneous extraction of five features per frame, combined with the GA optimization process, imposes a higher computational burden than fixed-parameter LMS. The method therefore targets platforms with moderate-to-high processing capability, such as embedded military communication units rather than ultra-low-power edge devices. The processing time (3.7–4.7 s across scenarios) remains acceptable for non-strict real-time applications but would benefit from further optimization for latency-critical scenarios.

Conclusions and Implications

The study demonstrates that the proposed **GA-optimized, five-feature-driven dynamic LMS filter** provides an effective, stable, and practical solution for military audio noise cancellation. By systematically integrating multiple signal descriptors and replacing manual parameter tuning with evolutionary optimization, the method achieves a meaningful 12.43 dB SNR improvement, a 1.56-fold error variance reduction, and consistent superiority over both fixed-parameter and manually-tuned baselines.

Practical implications include:

- Deployment as a pre-processing module in **military communication systems, surveillance, and command-and-control (C2) audio channels**.
- Use in **speech recognition front-ends** operating in hostile acoustic environments.
- Application as a **benchmark reference** for hybrid adaptive-intelligent filter designs in defense research.

Recommendations for future research:

- **Reducing computational load** through lightweight feature extraction techniques or surrogate-based optimization methods replacing the full GA.
- **Enhancing robustness** against emerging intelligent electronic noise by integrating frequency-domain features or lightweight AI models.
- **Extending validation** through hardware-in-the-loop implementation on field-deployable DSP/FPGA platforms and testing with real recorded military acoustic data.
- **Conducting perceptual evaluation** (e.g., PESQ, STOI) to complement the objective SNR/MSE metrics with subjective intelligibility scores.

Despite its demonstrated effectiveness, this study is limited to simulated noise scenarios; future work should validate the method under real battlefield acoustic conditions and across broader operational contexts, including underwater, vehicular, and aerial platforms.

بهبود عملکرد فیلتر تطبیقی LMS در حذف نویزهای نظامی با استفاده از بهینه‌سازی ترکیب پنج ویژگی سیگنال به کمک الگوریتم ژنتیک

نیما جعفری^۱، رضا اصفهانی^{۲*}

^۱ دانشجوی کارشناسی ارشد دانشگاه جامع امام حسین (ع)، تهران، ایران. رایانامه: jfrynyma672@gmail.com

^۲ استادیار دانشگاه جامع امام حسین (ع)، تهران، ایران (نویسنده مسئول). رایانامه: resfahani@ihu.ac.ir

چکیده

پردازش سیگنال‌های صوتی در محیط‌های نظامی به دلیل وجود نویزهای پیچیده‌ای مانند انفجار، شلیک سلاح و پارازیت‌های الکترومغناطیسی، همواره با چالش‌های متعددی روبرو بوده است. در این پژوهش، یک روش پیشرفته برای حذف نویزهای محیطی از سیگنال‌های صوتی نظامی ارائه شده که از یک فیلتر تطبیقی LMS با نرخ یادگیری پویا بهره می‌برد. نوآوری اصلی این تحقیق، به‌کارگیری هم‌زمان پنج ویژگی سیگنال ورودی شامل انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر برای تنظیم خودکار نرخ یادگیری است. ترکیب بهینه این ویژگی‌ها با استفاده از الگوریتم ژنتیک و با جمعیت ۵۰ کروموزوم در ۱۰ نسل انجام شده که ضرایب بهینه ۰/۸۴۸۶، ۰/۳۵۸۲، ۰/۹۱۹۵، ۰/۵۰۱۶، ۰/۱۸۷۲ را نتیجه داده است. نتایج آزمایش‌ها نشان می‌دهد روش پیشنهادی به بهبود ۱۲،۴۳ دسی‌بلی در نسبت سیگنال به نویز (از ۰/۱۸- به ۱۲/۲۵ دسی‌بل) و کاهش خطای میانگین مربعات به ۰/۰۱۶ دست یافته است. همچنین این روش بهبود ۱/۹۵ دسی‌بلی در SNR نسبت به فیلترهای ثابت و کاهش ۱/۵۶ برابری واریانس خطا را نشان می‌دهد. این الگوریتم با حفظ تعادل بین دقت و پیچیدگی، برای کاربردهای حیاتی نظامی مناسب است.

مشخصات مقاله

تاریخچه مقاله:

نوع مقاله: علمی پژوهشی

دریافت: ۱۴۰۴/۰۶/۲۵

بازنگری: ۱۴۰۴/۰۹/۰۸

پذیرش: ۱۴۰۵/۰۴/۲۲

ارائه آنلاین: ۱۴۰۵/۰۵/۳۰

کلیدواژه‌ها:

فیلتر تطبیقی

حذف نویز

پردازش صوت نظامی

نرخ یادگیری پویا

SNR

الگوریتم ژنتیک

بهینه‌سازی ضرایب

استناد: جعفری، نیما، اصفهانی، رضا، "بهبود عملکرد فیلتر تطبیقی LMS در حذف نویزهای نظامی با استفاده از بهینه‌سازی ترکیب پنج ویژگی سیگنال به کمک الگوریتم ژنتیک"، نشریه پدافند غیرعامل، دوره ۱۷، شماره ۲، صفحات ۴۵-۵۸، ۱۴۰۵.

DOI: <https://doi.org/10.47176/pd.2026.1576>

© نویسنده(گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.



ناشر: دانشگاه جامع امام حسین (ع).

OPEN ACCESS

۱- مقدمه

پردازش سیگنال‌های صوتی در محیط‌های نظامی به دلیل وجود نویزهای پیچیده، غیر ایستا و پراثری مانند انفجار، شلیک و پارازیت‌های الکترومغناطیسی، همواره با چالش‌های عملیاتی و امنیتی مواجه بوده است. هدف اصلی در این زمینه، حفظ وضوح و قابلیت درک گفتار در شرایطی است که نویزهای ضربه‌ای می‌توانند به‌طور کامل سیگنال مفید را مختل کنند.

روش‌های متداول از فیلترهای ثابت با ضعف در انعطاف‌پذیری تا فیلترهای تطبیقی مانند LMS با چالش تنظیم پارامتر ثابت و رویکردهای پیشرفته‌تری مانند فیلتر کالمن نیازمند مدل دقیق [۱] و [۲]، تبدیل موجک، پیچیدگی محاسباتی بالا و یادگیری عمیق [۳] و [۴] و [۵] وابسته به داده‌های حجیم توسعه یافته‌اند. نقطه ضعف مشترک این روش‌ها در محیط‌های نظامی، عدم ایجاد تعادل بهینه بین دقت، سرعت تطبیق، پیچیدگی محاسباتی و عدم وابستگی به مدل یا داده آموزشی است.

هدف این مقاله، ارائه یک راه‌حل نوآورانه و خودتنظیم برای غلبه بر این چالش است. نوآوری اصلی، طراحی یک فیلتر تطبیقی LMS با نرخ یادگیری پویا است که این نرخ به‌صورت لحظه‌ای و هوشمند، بر اساس ترکیب بهینه‌شده پنج ویژگی سیگنال (انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر) تنظیم می‌شود. بهینه‌سازی سهم هر ویژگی در این ترکیب، به‌طور سیستماتیک و با استفاده از الگوریتم ژنتیک انجام شده است تا سیستم بدون نیاز به تنظیم دستی یا مدل پیچیده، عملکرد بهینه‌ای در محیط‌های پویا و غیرقابل پیش‌بینی داشته باشد [۶] و [۷].

۲- روش تحقیق

۲-۱- کارهای مرتبط و سیر تحول موضوع

در بررسی کارهای مرتبط با حذف نویز صوتی در محیط‌های نظامی، سیر تحول موضوع نشان‌دهنده حرکت از روش‌های کلاسیک به سمت الگوریتم‌های هوشمند و تطبیقی است. در ابتدا، روش‌های مبتنی بر فیلترهای ثابت مانند فیلترهای FIR و IIR مورد استفاده قرار می‌گرفتند که اگرچه از پیچیدگی محاسباتی پایینی برخوردار بودند، اما به دلیل عدم انعطاف‌پذیری در محیط‌های متغیر نظامی، کارایی محدودی داشتند. سپس فیلترهای تطبیقی پایه و مانند LMS با نرخ یادگیری ثابت مطرح شدند که اگرچه بهبود نسبی در عملکرد ایجاد کردند [۸] و [۹]، اما در مواجهه با نویزهای ضربه‌ای معمول در محیط‌های نظامی عملکرد مطلوبی ارائه نمی‌دادند. در ادامه، روش‌های هوشمند مانند شبکه‌های عصبی [۱۰] [۱۱] و تبدیل موجک [۱۲] ظهور کردند که اگرچه دقت بالایی داشتند، اما پیچیدگی محاسباتی بسیار بالا و نیاز به داده‌های آموزشی گسترده، استفاده از آن‌ها را

در سیستم‌های بلادرنگ نظامی با محدودیت‌های سخت‌افزاری، دچار چالش می‌کرد. این امر منجر به توسعه روش‌های ترکیبی شد که با تلفیق مزایای روش‌های مختلف، در پی ایجاد تعادل بین دقت و پیچیدگی محاسباتی بودند [۱۳].

در جدول (۱) مهم‌ترین الگوها، مراجع شاخص، نقاط قوت و ضعف آن‌ها (با تأکید بر کاربرد نظامی) ارائه شده است.

جدول (۱): الگوهای حذف نویز و ویژگی‌هایشان

الگو	نمونه‌های کلیدی	نقاط قوت	نقاط ضعف (برای کاربرد نظامی)
ثابت	فیلترهای FIR/IIR	پیچیدگی بسیار پایین، پایداری	عدم انعطاف در برابر نویزهای غیر ایستا
تطبیقی پایه	الگوریتم‌های LMS, RLS [۱۴]	پیچیدگی متوسط، قابلیت تطبیق	وابستگی به پارامتر ثابت، عملکرد ضعیف در برابر نویز ضربه‌ای
مبتنی بر مدل	فیلتر کالمن	تخمین دقیق برای سیستم‌های خطی	نیاز ضروری به مدل دقیق و خطی از سیستم
زمان-فرکانس	تبدیل موجک، روش‌های هیبرید	حذف مؤثر نویزهای گذرا و فرکانس بالا	پیچیدگی بالا، حساسیت به انتخاب پایه، خطر اغوجاج

همان‌طور که مشاهده می‌شود، هیچ‌کدام از روش‌های موجود به‌تنهایی معیارهای کلیدی (عملکرد بالا در نویزهای غیر ایستا، (سریع بودن)، (سبک‌وزنی محاسباتی) و (عدم وابستگی به مدل/داده) را به‌طور هم‌زمان برآورده نمی‌کنند. این شکاف، انگیزه اصلی برای پژوهش حاضر و ارائه یک راه‌حل ترکیبی هوشمند و سبک بوده است [۱۵].

۲-۲- راهکار پیشنهادی


راهکار پیشنهادی این تحقیق در چند مرحله طراحی شده است. در مرحله اول، پنج ویژگی کلیدی سیگنال شامل انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر انتخاب و به صورت فریم به فریم از سیگنال ورودی استخراج شدند. انتخاب این ویژگی‌ها بر اساس این فرضیه بود که ترکیب آن‌ها می‌تواند درک جامعی از وضعیت سیگنال و نویز ارائه دهد. در مرحله بعد، از الگوریتم ژنتیک برای یافتن ضرایب بهینه ترکیب این ویژگی‌ها استفاده شد که در آن تابع برازندگی به گونه‌ای طراحی شده که هم‌زمان نسبت سیگنال به نویز را حداکثر و خطای میانگین مربعات را حداقل کند.

در مرحله سوم، یک سیستم فیلتر تطبیقی LMS با نرخ یادگیری پویا پیاده‌سازی شد که در آن نرخ یادگیری به صورت خودکار و بر اساس ترکیب وزنی ویژگی‌های استخراج شده تنظیم گردید. رابطه حاکم بر این سیستم به صورت یک ترکیب خطی از ویژگی‌های نرمال شده طبق رابطه (۹) طراحی شده که در آن ضرایب به دست آمده از الگوریتم ژنتیک، سهم هر ویژگی را در محاسبه نرخ یادگیری نهایی تعیین کردند. در نهایت، عملکرد سیستم پیشنهادی در سناریوهای مختلف نویزی و در مقایسه با روش‌های پایه و پیشرفته مورد ارزیابی جامع قرار گرفت.


۲-۲-۱ معماری و الگوریتم سیستم پیشنهادی

سیستم پیشنهادی مبتنی بر یک معماری نوآورانه است که از چندین ماژول به هم پیوسته تشکیل شده است. ورودی سیستم، سیگنال نویزی است که ابتدای فرآیند فریم بندی به بخش‌های کوتاه مدت تقسیم می‌شود. سپس طبق شکل (۱) و (۲) هر فریم به موازات دو مسیر اصلی پردازش می‌شود؛ در مسیر اول، یک فیلتر تطبیقی LMS با بهره‌گیری از الگوریتم حداقل مربعات میانگین، اقدام به فیلتراسیون سیگنال می‌کند. خروجی این فیلتر با سیگنال مرجع مقایسه شده و سیگنال خطا حاصل می‌شود که هم به عنوان خروجی نهایی سیستم و هم برای به روزرسانی ضرایب فیلتر مورد استفاده قرار می‌گیرد؛ نوآوری اصلی سیستم در مسیر دوم نهفته است. در این مسیر، پنج ویژگی کلیدی سیگنال شامل انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر (ZCR) به صورت بلادرنگ استخراج می‌شوند. این ویژگی‌ها سپس با ضرایب بهینه شده توسط الگوریتم ژنتیک ترکیب شده و نرخ یادگیری پویا برای فیلتر LMS تولید می‌کنند. مکانیسم کنترل پویا باعث می‌شود نرخ یادگیری به صورت هوشمندانه و بر اساس محتوای سیگنال تنظیم شود. در مواجهه با نویزهای ضربه‌ای، نرخ یادگیری افزایش یافته و در شرایط سیگنال تمیز، کاهش می‌یابد. این رویکرد تعادل بهینه‌ای بین سرعت همگرایی و پایداری

سیستم ایجاد می‌کند. خروجی نهایی سیستم، سیگنال تصفیه شده‌ای است که کیفیت ارتباطات صوتی در محیط‌های پر نویز نظامی را به طور قابل توجهی بهبود می‌بخشد. این معماری با پیچیدگی محاسباتی متوسط، قابلیت اجرا روی سخت‌افزارهای با منابع محدود را دارا است.



شکل (۱): معماری سیستم پیشنهادی



شکل (۲): بلوک دیاگرام الگوریتم پیشنهادی

احتمال تقاطع ۰,۷ و احتمال جهش ۰,۰۵ طبق طرح کلی تحلیل حساسیت الگوریتم ژنتیک در این مقاله در نظر گرفته شد. در جدول (۲) نتایج تحلیل حساسیت پارامترهای الگوریتم ژنتیک که منتج به اندازه جمعیت و تعداد نسل و احتمال تقاطع و جهش بهینه می‌شود به دست خواهد آمد.

جدول (۲): نتایج تحلیل حساسیت پارامترهای الگوریتم ژنتیک

پارامتر تحت بررسی	سطوح آزمایشی	بهترین برآورد (درصد)	نسل همگرایی
جمعیت	۳۰	۹۸,۵	۷۵
	۵۰	۱۰۰ مرجع	۱۰۰
	۷۰	۹۹,۸	۱۳۰
	۱۰۰	۹۹,۹	۱۸۰
نسل	۵	۹۷	۵۰
	۱۰	۱۰۰	۱۰۰
	۱۵	۱۰۰	۱۵۰
	۲۰	۱۰۰	۲۰۰
احتمال تقاطع	۰,۶	۹۹,۲	۹۵
	۰,۷	۱۰۰	۱۰۰
	۰,۸	۹۹,۷	۱۰۵
احتمال جهش	۰,۰۱	۹۸,۸	۹۸
	۰,۰۵	۱۰۰	۱۰۰
	۰,۰۵	۱۰۰	۱۰۰

توضیح: درصدها نسبتی از بهترین مقدار تابع برازندگی در حالت پایه (N_pop=50, N_gen=10, P_c=0/7, P_m=0/05 هستند). با توجه به تحلیل حساسیت سیستماتیک انجام شده، پارامترهای الگوریتم ژنتیک، جمعیت=۵۰، نسل=۱۰، P_c=0/7، P_m=0/05 نه تنها برای این مسئله کافی هستند، بلکه نقطه بهینه‌ای بین کیفیت جواب نهایی و هزینه محاسباتی ایجاد می‌کنند. همگرایی پایدار پس از ۷ نسل و مقاومت الگوریتم در برابر تغییرات جزئی پارامترها، نشان از قابلیت اطمینان روش بهینه‌سازی دارد.

در مرحله اول، پنج ویژگی کلیدی سیگنال شامل انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر انتخاب و به صورت فریم به فریم از سیگنال ورودی استخراج شده‌اند. این ویژگی‌ها به شرح زیر محاسبه می‌شوند:

ویژگی انرژی سیگنال ورودی در هر لحظه از رابطه (۱)، واریانس سیگنال از رابطه (۲)، آنتروپی از رابطه (۳)، نرخ گذر از صفر از رابطه (۴) و کوواریانس توسط رابطه (۵) به دست می‌آیند. رابطه (۱) انرژی بخش i ام سیگنال نویزی:

$$E_i = \sum_{m=0}^{L-1} |x_i(m)|^2$$

رابطه (۲) واریانس بخش i ام سیگنال نویزی:

$$\sigma^2_i = \frac{1}{L} \sum_{m=0}^{L-1} (x_i(m) - \mu_i)^2$$

که در آن μ_i میانگین فریم i ام است.

رابطه (۳) آنتروپی پنجره جاری

$$H(k) = - \sum_{i=1}^n p_i \log_2(p_i)$$

که در آن p_i احتمال وقوع مقدار i ام در سیگنال و n تعداد بازه‌ها است.

رابطه (۴) نرخ گذر از صفر پنجره جاری:

$$ZCR = \frac{1}{2(N-1)} \sum_{i=1}^{N-1} |\text{sign}(x_i) - \text{sign}(x_{i+1})|$$

که در آن x_i مقدار نمونه i ام در پنجره و N تعداد نمونه‌ها در پنجره است.

رابطه (۵) کوواریانس بین سیگنال و مربع آن در پنجره جاری:

$$\text{cov}(x, x^2) = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(x_i^2 - \overline{x^2})$$

که در آن x_i مقدار نمونه i ام در پنجره جاری، $\bar{x}$ میانگین نمونه‌های پنجره جاری، $\overline{x^2}$ میانگین مربع نمونه‌های پنجره جاری و N ل پنجره (تعداد نمونه‌ها در هر فریم) است.

در مرحله بعد، از الگوریتم ژنتیک برای یافتن ضرایب بهینه ترکیب این ویژگی‌ها استفاده شده است. پارامترهای الگوریتم ژنتیک شامل اندازه جمعیت ۵۰ کروموزوم، تعداد نسل ۱۰،

جدول (۳): معرفی پارامترهای رابطه (۹)

نماد	پارامتر
$\mu_{dynamic(k)}$	ام i پارامتر یادگیری پویا در نمونه
μ_0	پارامتر یادگیری اولیه
α	ضریب وزن دهی برای ترکیب پارامترها
E_i	ام سیگنال نویزی i انرژی بخش
E_{max}	مقدار بیشینه برای نرمال سازی
σ_i^2	ام سیگنال نویزی i واریانس بخش
σ_{max}^2	مقدار بیشینه برای نرمال سازی
H_k	آنتروپی پنجره جاری
H_{max}	مقدار بیشینه برای نرمال سازی
ZCR	نرخ گذر از صفر پنجره جاری
ZCR_{max}	مقدار بیشینه برای نرمال سازی
cov	کوواریانس بین سیگنال و مربع آن در پنجره جاری
cov_{max}	مقدار بیشینه برای نرمال سازی

که در آن ضرایب بهینه α از الگوریتم ژنتیک به دست آمده و برابر است با:

$$\alpha = [0/8486, 0/1872, 0/5016, 0/9195, 0/3582]$$

نتایج بهینه سازی با الگوریتم ژنتیک منجر به شناسایی ضرایب بهینه برای ترکیب ویژگی ها شد. این ضرایب نشان می دهند که آنتروپی با ضریب ۰,۹۱۹۵، بیشترین اهمیت و واریانس با ضریب ۰,۱۸۷۲، کمترین اهمیت را در تعیین نرخ یادگیری پویا دارند.

۲-۲-۲- روابط عملکرد فیلتر تطبیقی پارامتر متغیر

فیلتر پیشنهادی (۵ پارامتری) بر اساس پارامترهای هر فریم، خود را تنظیم می کند:

تابع برازندگی طبق رابطه (۷) به گونه ای طراحی شده که همزمان نسبت سیگنال به نویز را حداکثر و خطای میانگین مربعات را حداقل کند.

رابطه (۶) تابع برازندگی:

$$Fitness = w_1 * SNR_{output} - w_2 * MSE$$

که در آن SNR_{output} نسبت سیگنال به نویز خروجی بر حسب دسی بل، از طریق رابطه (۷) و MSE میانگین مربعات خطاست که از طریق رابطه (۸) به دست می آیند.

رابطه (۷) نسبت سیگنال به نویز خروجی:

$$SNR = 10 \log_{10} \left(\frac{\sum |x_{clean}(n)|^2}{\sum |x_{clean}(n) - \hat{x}(n)|^2} \right)$$

که در آن $x_{clean}(n)$ سیگنال اصلی بدون نویز و $\hat{x}(n)$ سیگنال فیلتر شده است.

رابطه (۸) میانگین مربعات خطا:

$$MSE = \frac{1}{N} \sum_{n=0}^{N-1} (x_{clean}(n) - \hat{x}(n))^2$$

در رابطه (۶)، w_1 و w_2

ضرایب وزنی هستند که به ترتیب مقادیر ۰,۷ و ۰,۲ به آن ها اختصاص داده شده است.

جمله اول تابع، $w_1 * SNR_{output}$ به حداکثر کردن نسبت سیگنال به نویز می پردازد. ضریب وزنی ۰,۷ نشان دهنده اهمیت بالای این معیار در ارزیابی عملکرد است؛ جمله دوم $-w_2 * MSE$ به حداقل کردن خطای میانگین مربعات توجه دارد. علامت منفی تضمین می کند که با کاهش MSE ، مقدار تابع برازندگی افزایش یابد.

این تابع برازندگی به گونه ای طراحی شده است که همزمان به بهبود دو شاخص کلیدی عملکرد سیستم می پردازد و تعادل مناسبی بین دقت پردازش و پایداری سیستم برقرار می کند. یک جدول خلاصه که نشان دهد تغییر هر پارامتر چگونه بر معیارهای کلیدی تأثیر می گذارد.

در مرحله سوم، یک سیستم فیلتر تطبیقی LMS با نرخ یادگیری پویا پیاده سازی شده است که در آن نرخ یادگیری به صورت خودکار و بر اساس ترکیب وزنی ویژگی های استخراج شده تنظیم می گردد. رابطه حاکم بر این سیستم به صورت رابطه (۹) طراحی شده است.

رابطه نرخ یادگیری پویا (۹)

$$\mu_{dynamic(k)} = \mu_0 * \left(1 + \alpha_1 \frac{E_i}{E_{max}} + \alpha_2 \frac{\sigma_i^2}{\sigma_{max}^2} + \alpha_3 \frac{H_k}{H_{max}} + \alpha_4 \frac{ZCR_k}{ZCR_{max}} + \alpha_5 \frac{cov_k}{cov_{max}} \right)$$

جدول (۵): مقایسه عملکرد روش پیشنهادی با روش ضرایب دستی

معیار	LMS با ضرایب دستی	روش پیشنهادی	تحلیل عملکرد
SNR اولیه	-۰,۱۷۶۸۱ dB	dB-۰,۱۷۶۸۱	برابر
SNR خروجی	۱۱,۹۹۱۵ dB	۱۲,۲۵۲۵ dB	فیلتر با ضرایب بهینه SNR بهتری دارد
بهبود SNR	۱۲,۱۶۸۳ dB	۱۲,۴۲۹۳ dB	فیلتر با ضرایب بهینه
برتری روش ضرایب بهینه در SNR	۰,۲۶۱ dB		میزان SNR ۰,۲۶۱ بهتری دارد
MSE	۰,۰۰۱۶۹۹۳	۰,۰۰۱۶۰۰۲	دقت بالاتر
برتری روش ضرایب بهینه در MSE	۰,۰۰۰۰۹۹۱		ضرایب بهینه در کاهش خطا

۲-۲-۴- مقایسه جامع عملکرد روش‌های مختلف در سناریوهای نویزی متفاوت

جدول (۶): مقایسه جامع عملکرد روش‌های مختلف در سناریوهای

نویزی متفاوت

معیار	نویز ترکیبی (تیر+موتور)	نویز ضربه‌ای (انفجار)	نویز سفید گوسی	میانگین بهبود
ارزیابی	پیشنهادی ثابت	پیشنهادی ثابت	پیشنهادی ثابت	
بهبود SNR (dB)	۱۰,۴۸-۱۲,۴۳	۹,۵-۱۱,۸۰	-۱۳,۲۰-۱۱,۱۰	۱۲,۴۳
MSE ($\times 10^{-4}$)	۲۵,۱-۱۶,۰	۳۰,۲-۱۸,۵	۲۰,۵-۱۴,۲	۱۶,۲
زمان پردازش (ثانیه)	۴,۵-۳,۸	۳,۹-۴,۷	۳,۷-۴,۳	۴,۵
واریانس خطا	-۰,۰۰۱۰-۰,۰۰۱۶	-۰,۰۰۱۲-۰,۰۰۱۹	-۰,۰۰۰۹-۰,۰۰۱۴	۰,۰۰۱۰

در فریم‌های بالارژی بالا (سیگنال قوی)، فیلتر تأثیر کمتری دارد تا جزئیات سیگنال حفظ شود.

در فریم‌های بالارژی پایین (نویز غالب)، فیلتر به صورت قوی تر عمل می‌کند. معادله فیلتر تطبیقی به صورت رابطه (۱۰) است.

$$\hat{x}_i(m) = \sum_{k=0}^M h_i(k) \cdot x_i(m-k)$$

که در آن:

$h_i(k)$ معایب فیلتر در فریم i ام هستند و با رابطه (۱۱) و (۱۲) به می‌شوند.

رابطه (۱۱)

$$h_i(k) = h_{base}(k) \cdot \Delta h_i(k)$$

رابطه (۱۲)

$$\Delta h_i(k) = \alpha \cdot \frac{\sigma_i^2}{\sigma_{max}^2}$$

۲-۲-۳- مقایسه عملکرد حذف نویز

نتایج مقایسه عملکرد روش پیشنهادی با روش μ ثابت در جدول (۴) ارائه شده است.

جدول (۴): مقایسه عملکرد روش μ ثابت و پیشنهادی

معیار	LMS با μ ثابت	روش پیشنهادی
SNR خروجی (dB)	۱۰,۳۰	۱۲,۲۵
بهبود SNR (dB)	۱۰,۴۸	۱۲,۴۳
MSE	۰,۰۰۲۵۱	۰,۰۰۱۶۰

۱- مقایسه دو روش بهبود نویز روش پیشنهادی با ضرایب دستی نتایج مقایسه عملکرد روش پیشنهادی با روش ضرایب دستی در جدول (۵) ارائه شده است.

در این بخش، عملکرد روش پیشنهادی مبتنی بر بهینه‌سازی ضرایب فیلتر LMS با الگوریتم ژنتیک، در بستر گسترده‌تری از الگوهای رایج حذف نویز مورد بررسی قرار می‌گیرد. جدول (۷) مقایسه‌ای جامع از شاخص‌های کلیدی بین چهار رویکرد اصلی شامل فیلتر کالمن، تبدیل موجک، روش‌های مبتنی بر یادگیری عمیق و روش پیشنهادی حاضر (LMS با ضرایب بهینه‌شده با الگوریتم ژنتیک) ارائه می‌دهد.


از نظر معیارهای عملکردی خالص، روش‌های یادگیری عمیق با قابلیت یادگیری الگوهای بسیار پیچیده و غیرخطی، بهترین بازه عملکردی را در بهبود SNR (۲۵ تا ۳۰ دسی‌بل) و کمترین (0/002-0/0015 MSE) نشان می‌دهند. در رده بعدی، تبدیل موجک با مزیت تجزیه چندمقیاسی و حذف مؤثر نویزهای فرکانس بالا و سپس فیلتر کالمن با تخمین دقیق در سیستم‌های دینامیک قرار دارند. روش پیشنهادی با دستیابی به بهبود 12/43 دسی‌بلی در SNR و MSE معادل 0/00160 هرچند از نظر عددی در رده پایین‌تری قرار می‌گیرد، اما این عملکرد را در چارچوبی کاملاً تطبیقی، هوشمند و بدون نیاز به مدل از پیش تعریف‌شده از نویز یا داده‌های آموزشی حجیم ارائه می‌کند. این در حالی است که برتری روش‌هایی مانند یادگیری عمیق منوط به در اختیار داشتن مجموعه داده‌های عظیم و متنوع از محیط عملیاتی است.

نکته تعیین‌کننده در انتخاب روش، تلفیق کارایی با ملاحظات عملیات واقعی است. همان‌طور که در جدول مشاهده می‌شود، روش‌های با عملکرد عددی بالاتر، هزینه محاسباتی و پیچیدگی اجرایی به‌مراتب بیشتری را تحمیل می‌کنند. یادگیری عمیق با زمان پردازش و پیچیدگی محاسباتی بسیار بالا و تبدیل موجک با حساسیت به انتخاب موجک پایه و خطر ایجاد اعوجاج همراه هستند. فیلتر کالمن نیز نیازمند مدل دقیق و خطی از دینامیک سیستم است که در محیط‌های نامعین نظامی همواره در دسترس نیست.

در این مقایسه، نقاط قوت متمایز روش پیشنهادی شامل بهبود قابل توجه و پایدار در SNR، کاهش مؤثر واریانس خطا و مهم‌تر از همه، بهینه‌سازی خودکار پارامترها بدون نیاز به مدل سیستم یا داده‌های آموزشی انبوه است. این ویژگی‌ها، آن را به‌ویژه برای محیط‌های نظامی دینامیک و غیرقابل پیش‌بینی که در آن‌ها دسترسی به مدل دقیق یا داده‌های آموزشی جامع میسر نیست، بسیار مناسب می‌سازد. با این حال، این روش ملاحظات عملی خود را دارد که اصلی‌ترین آن بار محاسباتی مرتبط با استخراج هم‌زمان پنج پارامتر ویژگی و پیچیدگی پیاده‌سازی مرتبط با بخش بهینه‌سازی الگوریتم ژنتیک است که زمان پردازش و پیچیدگی آن را در رده بالا قرار می‌دهد.

در جدول (۶) مقایسه جامع عملکرد روش‌های مختلف در سناریوهای نویزی متفاوت نشان می‌دهد که روش پیشنهادی در تمامی سناریوهای نویزی، برتری خود را نسبت به فیلتر ثابت حفظ کرده و به‌طور میانگین ۱۲/۴۳ دسی‌بل بهبود SNR و کاهش ۳۵٪ در MSE داشته است.

طبق نمودار شکل، رابطه مستقیم بین افزایش ناگهانی انرژی و افزایش خودکار نرخ یادگیری را نشان می‌دهد که علت اصلی عملکرد برتر سیستم است.




نمودار (۱): μ و انرژی

۲-۲-۵- تحلیل عملکرد و ملاحظات عملی روش پیشنهادی


مقایسه جامع حذف نویز در روش‌های مختلف (کالمن، تبدیل موجک و یادگیری عمیق) در جدول (۷) ارائه شده است.

جدول (۷): مقایسه جامع حذف نویز در روش‌های مختلف


معیار	فیلتر کالمن	تبدیل موجک	یادگیری عمیق (الگوریتم ژنتیک)	LMS با ضرایب بهینه
SNR بهبود یافته	۱۵-۲۰	۱۸-۲۲	۲۵-۳۰	۱۲،۴۳
MSE	-۰،۰۰۴ ۰،۰۰۲۸	-۰،۰۰۳ ۰،۰۰۲۲	-۰،۰۰۱۵ ۰،۰۰۰۲	۰،۰۰۱۶۰
زمان پردازش	متوسط	بالا	بسیار بالا	بالا
پیچیدگی محاسباتی	متوسط	بالا	بسیار بالا	بالا
نقاط قوت	-مناسب برای سیستم‌های دینامیک -تخمین دقیق	-حذف نویز -فرکانس بالا -تجزیه چندمقیاسی	-یادگیری الگوهای پیچیده -عملکرد عالی در نویزهای غیرخطی	-بهبود ۱۲،۴۳ در SNR -کاهش 1/56 برای واریانس خطا -بهینه‌سازی خودکار پارامترها
نقاط ضعف	-نیاز به مدل دقیق سیستم -پیچیدگی محاسباتی	-حساس به انتخاب موجک پایه -ایجاد اعوجاج	-نیاز به داده آموزشی زیاد -منابع محاسباتی سنگین	-نیاز به محاسبه ۵ پارامتر -پیچیدگی پیاده‌سازی الگوریتم ژنتیک



شکل (۴): نرخ ویژگی‌های استخراج شده از سیگنال



شکل (۵): واریانس، کوواریانس و آنتروپی و همچنین نرخ تغییرات پارامتر متغیر μ




شکل (۶): نتایج عددی اجرای الگوریتم

انتخاب روش بهینه، یک تصمیم مبتنی بر موازنه‌سازی است. روش پیشنهادی حاضر، موقعیت خود را به‌عنوان راه‌حلی هوشمند، خود تطبیق و متعادل در این طیف تعریف می‌کند. این روش برای کاربردهای حیاتی نظامی که در آن‌ها قابلیت اطمینان، پایداری در شرایط متغیر و عدم وابستگی به داده‌های آموزشی حجیم اولویتی هم‌تراز یا بالاتر از حداکثر سازی مطلق بهبود SNR دارند، گزینه‌ای به‌شدت رقابتی و کاربردی محسوب می‌شود. این الگوریتم نشان می‌دهد که با در نظرگیری محدودیت‌های واقعی محیط عملیاتی، می‌توان به سطحی مطلوب از عملکرد دست‌یافت که پیاده‌سازی آن در سکوی‌های پردازشی متداول در میدان نبرد، امکان‌پذیر باشد.

۳- نتایج

در تصاویر زیر، شکل‌های (۳) و (۴) و (۵) و (۶) و (۷) نتایج اجرای الگوریتم پیشنهادی مشاهده می‌شود؛ قابل ذکر است که نمودار تغییرات نرخ یادگیری پویا در طول زمان در شکل (۵) به‌وضوح نشان می‌دهد که این پارامتر به‌جای ثابت بودن، به‌صورت پویا و مبتنی بر محتوای سیگنال تنظیم می‌شود. در لحظاتی که سیگنال ورودی حاوی نویزهای ضربه‌ای قوی (مانند صدای انفجار یا شلیک) است، نرخ یادگیری به‌صورت خودکار افزایش می‌یابد تا فیلتر بتواند با سرعت بیشتری همگرا شده و این نویزها را سرکوب کند. در مقابل، در بازه‌های زمانی که سیگنال نسبتاً تمیز است یا نویزهای کم‌انرژی غالب هستند، نرخ یادگیری کاهش می‌یابد تا از بروز نوسانات اضافی در ضرایب فیلتر و اعوجاج سیگنال مفید جلوگیری شود. این رفتار هوشمندانه، علت بهبود عملکرد سیستم پیشنهادی نسبت به فیلترهای با نرخ یادگیری ثابت است.



شکل (۳): طیف زمانی و فرکانسی سیگنال اصلی

عملکرد خوب، پیچیدگی متوسط، عدم نیاز به مدل/داده آموزشی حجیم و قابلیت اجرای بلادرنگ برقرار می‌کند.

۴- بحث و نتیجه‌گیری

این پژوهش به طراحی و ارزیابی یک سیستم هوشمند برای حذف نویز از سیگنال‌های صوتی در محیط‌های پر چالش نظامی پرداخت. هسته روش پیشنهادی، یک فیلتر تطبیقی LMS با نرخ یادگیری پویا است که پارامتر یادگیری آن به صورت لحظه‌ای و بر اساس ترکیب بهینه‌شده‌ای از پنج ویژگی سیگنال (انرژی، واریانس، کوواریانس، آنتروپی و نرخ گذر از صفر) تنظیم می‌شود. نوآوری اصلی، استفاده از الگوریتم ژنتیک برای یافتن ضرایب بهینه ترکیب این ویژگی‌ها به جای اتکا به تنظیم دستی یا مقادیر ثابت بود.

نتایج تجربی نشان داد که روش پیشنهادی در سناریوهای شبیه‌سازی‌شده نویزهای نظامی به بهبود قابل توجهی در کیفیت سیگنال دست یافت. این روش نسبت به فیلتر LMS با نرخ یادگیری ثابت، بهبود عملکرد معنادار و کاهش واریانس خطا را محقق ساخت که بیانگر پایداری و قابلیت اطمینان برتر در شرایط غیر ایستا است.

مقایسه جامع‌تر، موقعیت متعادل و کاربردی روش پیشنهادی را آشکار می‌سازد. اگرچه روش‌هایی مانند یادگیری عمیق یا تبدیل موجک در محیط‌های ایده‌آل ممکن است اعداد عملکردی بالاتری گزارش دهند، اما روش حاضر با پرهیز از پیش‌فرض‌های سنگین، مزایای متمایزی ارائه می‌دهد از جمله، استقلال از داده‌های آموزشی حجیم، عدم نیاز به مدل دقیق سیستم و هوشمندی خودکار حاصل از بهینه‌سازی سیستماتیک با الگوریتم ژنتیک.

با این حال، دستیابی به این سطح از هوشمندی بدون هزینه نیست. اصلی‌ترین چالش، بار محاسباتی و زمان پردازش نسبتاً بالاتر ناشی از استخراج هم‌زمان پنج ویژگی و فرآیند بهینه‌سازی است که کاربرد آن را به پلتفرم‌های پردازشی با قابلیت متوسط به بالا مشروط می‌کند. این تحقیق نشان داد که ترکیب هوشمندانه ویژگی‌های سیگنال در یک چارچوب بهینه‌شده و تطبیقی، می‌تواند راه‌حلی مؤثر و عملی برای مشکل نویز در ارتباطات صوتی نظامی باشد. روش پیشنهادی با برقراری تعادل آگاهانه بین دقت، پایداری، هوشمندی و پیچیدگی محاسباتی، نه تنها عملکرد فیلتر LMS را به‌طور قابل توجهی ارتقا می‌دهد، بلکه گامی به‌سوی سیستم‌های پردازش سیگنال خودتنظیم و مقاوم در محیط‌های نامعین است.

۴-۱- پیشنهادها برای کارهای آینده

با توجه به نتایج، پیشنهاد می‌شود مطالعات آتی در راستای کاهش بار محاسباتی (از طریق روش‌های استخراج ویژگی

```
Command Window
Alpha: [0.9290, 0.7397, 0.7891, 0.2610, 0.5885]
Behtarin zarayeb alpha (genetic): [0.8486, 0.1872, 0.5016, 0.9195, 0.3582]
MSE (Dynamic, Genetic): 0.0016002
MSE (Dynamic, Manual): 0.0016993
MSE (Fixed): 0.0025063
SNR Before: -0.17681 dB
SNR Dynamic (Genetic): 12.2525 dB
SNR Dynamic (Manual): 11.9915 dB
SNR Fixed: 10.3039 dB
Improvement in SNR (Dynamic, Genetic): 12.4293 dB
Improvement in SNR (Dynamic, Manual): 12.1683 dB
Improvement in SNR (Fixed): 10.4807 dB
fx>>
```

شکل (۷): نتایج عددی اجرای الگوریتم

نمودارهای مربوط به تغییرات پنج ویژگی استخراج‌شده در طول زمان در شکل (۵) رابطه مستقیم بین این ویژگی‌ها و نرخ یادگیری پویا را نشان می‌دهند:

انرژی؛ در لحظات وقوع نویزهای ضربه‌ای، انرژی سیگنال به‌صورت ناگهانی افزایش می‌یابد که مستقیماً منجر به افزایش نرخ یادگیری می‌شود.

واریانس؛ تغییرات سریع در دامنه سیگنال (مانند تغییر از سکوت به گفتار یا نویز) باعث افزایش واریانس شده و سهم خود را در تنظیم نرخ یادگیری ایفا می‌کند.

آنتروپی؛ این ویژگی در بازه‌هایی که سیگنال غیرقابل پیش‌بینی است (مانند ترکیب گفتار و نویزهای پیچیده) افزایش یافته و بیشترین تأثیر را در افزایش نرخ یادگیری دارد.

نرخ گذر از صفر؛ در حضور نویزهای با محتوای فرکانسی بالا (مانند صدای تیراندازی)، این ویژگی افزایش یافته و سهم خود را در کنترل پویای سیستم اعمال می‌کند.

کوواریانس؛ این پارامتر برای تشخیص روابط غیرخطی بین سیگنال و نویز عمل کرده و در لحظات تغییرات ناگهانی، نقش مکمل را ایفا می‌کند.

همان‌طور که در نتایج شکل (۷) مشاهده می‌شود، روش پیشنهادی نسبت به فیلتر LMS ثابت بهبود ۱٫۹۵ دسی‌بلی در SNR و نسبت به روش با ضرایب دستی بهبود ۰٫۲۶ دسی‌بلی را نشان می‌دهد. همچنین کاهش ۱/۵۶ برابری واریانس خطا نشان‌دهنده پایداری بالاتر سیستم پیشنهادی است. الگوریتم ژنتیک ضرایب بهینه برای ترکیب ۵ ویژگی را یافت.

[0/8486, 0/1872, 0/5016, 0/9195, 0/3582]

آنتروپی با بیشترین ضریب (۰٫۹۱۹۵)، مهم‌ترین ویژگی در محیط‌های نویزی نظامی بود.

عملکرد برتر سیستم پیشنهادی در شبیه‌سازی‌ها، به میانگین بهبود ۱۲٫۴۸ دسی‌بلی SNR و کاهش MSE به ۰٫۰۱۶۲ دست یافت.

نمودارها رابطه مستقیم و هوشمندانه بین افزایش ناگهانی ویژگی‌ها (مثلاً هنگام انفجار) و افزایش خودکار نرخ یادگیری را تأیید کردند.

مقایسه کیفی نشان داد این روش، تعادل مطلوبی بین

OptimizationIssues: Application, Advantages and Disadvantages," *Passive Defense*, vol. 4, pp. 13-24, 2014(In Persian).

سبک‌تر یا الگوریتم‌های بهینه‌سازی کم‌هزینه‌تر) و افزایش مقاومت الگوریتم (با بررسی ادغام ویژگی‌های مبتنی بر حوزه فرکانس یا روش‌های هوش مصنوعی سبک‌وزن [۱۶] برای مقابله با نویزهای الکترونیکی هوشمند) دنبال شوند. این سیستم می‌تواند به‌عنوان یک ماژول پردازش پیش‌تصفیه مؤثر در سامانه‌های ارتباطی، شنود و تشخیص گفتار در محیط‌های امنیتی و نظامی مورد بهره‌برداری قرار گیرد

۵- مراجع

- [1] M. S. Grewal, *International Encyclopedia of Statistical Science*, Berlin, Heidelberg: Springer, 2025.
M. Lovric (ed.), *International Encyclopedia of Statistical Science*, Berlin, Heidelberg: Springer, 2011.
- [2] A. Yaghootian, "Estimation of ultrasonic waveform using Kalman filter," *Journal of Acoustical Signal Processing*, 2021.
- [3] C. Jannu and S. D. Vanambathina, "An overview of speech enhancement based on deep learning techniques," *International Journal of Image and Graphics*, 2025.
- [4] Y. Xu, X. Li and Y. Wu, "Deep learning for speech enhancement: A survey," *IEEE Transactions on Audio, Speech, and Language Processing*, 2023.
- [5] S. Kour, P. Sharma, A. M. Zargar, A. Sonania, T. Hassan and N. Nijamuddin, "Emotion recognition from speech signals using hybrid CNN model," in *Proceedings of the 3rd International Conference on Advancement in Computation & Computer Technologies (InCACCT)*, 2025.
- [6] S. Boll, "Suppression of acoustic noise in speech using spectral subtraction," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 27, no. 2, pp. 120-113, 1979.
- [7] H. D. Hesar and A. D. Hesar, "Adaptive dual augmented extended Kalman filtering of ECG signals," *Measurement*, 2024.
- [8] V. S. R. Kumari and D. K. Devarakonda, "A wavelet based denoising of speech signal," in *Proceedings of International Conference on Signal Processing*, 2013.
- [9] M. Shanthamallappa, K. Puttegowda, N. K. H. Nannappa and e. al, "Robust automatic speech recognition using wavelet-based adaptive wavelet thresholding: A review," *SN Computer Science*, 2024.
- [10] S. Talati and R. Esfahani, "Presenting a New Method of Image Steganalysis Based on MLP Neural Network," *Passive Defense*, 2023(In Persian).
- [11] M. R. Hasani Ahangar and M. Akhzami, "Fault Tolerance in the MLP Neural Networks Using Triple Modular Redundancy," *Passive Defense*, vol. 4, pp. 51-61, 2013(In Persian).
- [12] R. Esfahani and A. R. Matinfar, "Steganography Audio Based on Zero-Tree Wavelet Transform Algorithm," *Passive Defense*, vol. 14, pp. 115-130, 2023(In Persian).
- [13] S. Haykin, *Adaptive Filter Theory*, Englewood Cliffs, NJ, USA: Prentice Hall, 2002.
- [14] N. K. Yadav, A. Dhawan, M. Tiwari and e. al, "Modified model of RLS adaptive filter for noise cancellation," *Circuits, Systems, and Signal Processing*, 2024.
- [15] Y. Iqbal, T. Zhang, T. S. Gunawan, S. A. Raza, I. Habib and F. Jiang, "A hybrid speech enhancement technique based on discrete wavelet transform and spectral subtraction," *IEEE Access*, vol. 13, 2025.
- [16] M. R. Hasani Ahangar and A. Moghaddasi, "The Study and Introducing Artificial Intelligence Algorithm to Solve