

الگوریتم مبتنی بر شبکه تطبیقی نفوذی برای تخمین مقاوم میدان اسکالر در شبکه‌های سنسوری بی‌سیم

امیر رستگاریان^۱، استادیار؛ اعظم خلیلی^۲، استادیار؛ توحید یوسفی رضایی، استادیار^۳

۱- گروه مهندسی برق - دانشگاه ملایر - ملایر - ایران - a_rastegar@ieee.org

۲- گروه مهندسی برق - دانشگاه ملایر - ملایر - ایران - a.khalili@ieee.org

۳- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - yousefi@tabrizu.ac.ir

چکیده: در این مقاله الگوریتمی برای تخمین مقاوم میدان اسکالر با استفاده از یک شبکه سنسوری بی‌سیم که در آن تعدادی از گره‌های شبکه دارای کیفیت مشاهدات بسیار پایین ناشی از نویز ضربه‌ای هستند پیشنهاد می‌گردد. بدین منظور، ابتدا تخمین مقاوم میدان اسکالر به‌صورت یک مسئله بهینه‌سازی با تابع هزینه مبتنی بر بیشینه correntropy بیان شده و در ادامه الگوریتمی برای حل مسئله مبتنی بر شبکه تطبیقی نفوذی ارائه می‌گردد. برای بررسی عملکرد الگوریتم، نحوه عملکرد آن بر روی تخمین میدان اسکالر شبیه‌سازی شده و با برخی از روش‌های موجود، از جمله شبکه تطبیقی مبتنی بر معیار کم‌ترین مربع خطا (LMS) مقایسه شده است. نتایج به دست آمده نشان‌دهنده کارایی مناسب الگوریتم پیشنهادی است.

واژه‌های کلیدی: شبکه تطبیقی، میدان اسکالر، شبکه نفوذی، تخمین توزیع‌شده.

A Diffusion Adaptive Network Algorithm for Robust Scalar Field Estimation in Wireless Sensor Networks

A. Rastegarnia¹, Assistant Professor; A. Khalili², Assistant Professor; T. Yousefi Rezaii³, Assistant Professor

1- Department of Electrical Engineering, University of Malayer, Malayer, Iran, Email: a_rastegar@ieee.org

2- Department of Electrical Engineering, University of Malayer, Malayer, Iran, Email: a.khalili@ieee.org

3- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: yousefi@tabrizu.ac.ir

Abstract: In this paper, a robust scalar field estimation algorithm for wireless sensor networks that contain some nodes with very low quality observations, due to impulsive noise, is proposed. To derive the proposed algorithm, we first recast the robust scalar field estimation as an optimization problem with a maximum correntropy cost function. Then, we develop a distributed solution for it based on the diffusion adaptive network. We evaluate the performance of the proposed algorithm on a scalar field estimation problem and compare it with some similar algorithms, such as diffusion LMS algorithm. Simulation results show the superior performance of the proposed algorithm.

Keywords: Adaptive networks, scalar field, diffusion network, distributed estimation.

تاریخ ارسال مقاله: ۱۳۹۴/۱۲/۲۰


تاریخ اصلاح مقاله: ۱۳۹۵/۰۳/۰۱

تاریخ پذیرش مقاله: ۱۳۹۵/۰۶/۱۵

نام نویسنده مسئول: امیر رستگاریان

نشانی نویسنده مسئول: ایران - ملایر - کیلومتر ۴ جاده اراک - دانشگاه ملایر - دانشکده فنی و مهندسی.

۱- مقدمه



شکل ۱: انواع استراتژی مورد استفاده در شبکه تطبیقی: استراتژی افزایشی (چپ)، استراتژی نفوذی (راست)

در مقابل، استراتژی‌های نفوذی در برابر خرابی‌های گره یا لینک و توانایی تطبیق با وجود تغییرات در توپولوژی شبکه و یا آمارگان داده‌ها مقاوم می‌باشد [۱۹-۱۷]. این استراتژی‌ها علاوه بر حل مسئله تخمین توزیع شده برای مدل‌سازی رفتارهای خودسازمانده و پیچیده در شبکه‌های زیستی و همچنین حل مسئله مربوط به موقعیت‌یابی به کار برده شده‌اند [۲۰].

یکی از کاربردهای مهم شبکه‌های سنسوری بی‌سیم تخمین یک میدان اسکالر است. به لحاظ ریاضی، یک میدان اسکالر تابعی است که به هر نقطه از فضا مقدار مشخصی از یک کمیت فیزیکی اسکالر (مانند دما، فشار، غلظت مواد آلاینده شیمیایی و غیره) را نظیر می‌کند. به عبارت دیگر، یک میدان اسکالر توزیعی فضایی از یک کمیت اسکالر است. در مسئله تخمین میدان با شبکه‌های سنسوری بی‌سیم، هدف نهایی استفاده از مشاهدات نویزی سنسورهای توزیع شده در نقاط خاص برای تخمین مقدار میدان اسکالر در هر نقطه از فضا می‌باشد. الگوریتم‌های مختلفی برای حل مسئله تخمین میدان با استفاده از شبکه‌های سنسوری بی‌سیم ارائه شده است [۲۶-۲۱]. با این حال الگوریتم‌های اشاره شده یا مبتنی بر FC بوده و یا فاقد ویژگی تطبیقی بودن می‌باشند.

در این مقاله ابتدا نشان داده می‌شود که چگونه از شبکه تطبیقی نفوذی برای حل مسئله تخمین میدان اسکالر می‌توان استفاده نمود. در ادامه، الگوریتمی مقاوم برای تخمین میدان اسکالر پیشنهاد می‌گردد که در آن علی‌رغم وجود تعدادی از گره‌های شبکه که به داده‌های با کیفیت بسیار پایین ناشی از نویز ضربه‌ای دسترسی داشته (و در نتیجه تخمین‌های با خطای بالا ایجاد می‌کنند) کارایی کل الگوریتم چندان تحت تأثیر قرار نگیرد. برای مدل‌سازی داده‌های با کیفیت بسیار پایین می‌توان از مدل نویز ضربه‌ای استفاده نمود [۲۹-۲۷]. در واقع یکی از ایرادهای اساسی الگوریتم‌های تطبیقی مبتنی بر معیار کم‌ترین مربع خطا (مانند الگوریتم LMS^5) کاهش شدید کارایی آن‌ها در حضور مشاهدات آغشته به نویز ضربه‌ای است. بنابراین برای داشتن الگوریتم مقاوم ناچار به استفاده از معیاری غیر از معیار کم‌ترین مربع خطا در الگوریتم تطبیقی می‌باشیم. از این رو در الگوریتم پیشنهادی به جای استفاده از معیار کم‌ترین مربع خطا در الگوریتم تطبیقی، از معیار بیشینه correntropy^6 (MCC) استفاده شده است. در ادامه، با استفاده از روش تندترین صعود^۱ و تقریب‌های آماری مناسب الگوریتم تطبیقی

از جمله مسائلی که به طور گسترده در بسیاری از کاربردهای مرتبط با پردازش سیگنال ظاهر می‌گردد مسئله تخمین توزیع شده است که در آن هدف نهایی تخمین یک پارامتر نامعلوم یا تعقیب یک سیگنال مطلوب با استفاده از مشاهدات (نمونه‌های) نویزی قابل دسترس در گره‌های مختلف یک شبکه می‌باشد. چنین مسائلی را می‌توان در گستره وسیعی از کاربردهای امروزی از جمله سیستم‌های مخابراتی، سیستم‌های قدرت، پردازش سیگنال‌های حیاتی، شبکه‌های سنسوری بی‌سیم مشاهده نمود [۱]. بسته به نوع توپولوژی مورد استفاده در پیاده‌سازی شبکه مورد نظر (یعنی وجود یا عدم وجود مرکز پردازش^۱ (FC))، راه‌حل مورد استفاده برای مسئله تخمین توزیع شده متفاوت خواهد بود. در بسیاری از کاربردهای مورد اشاره، یا ناچار به پیاده‌سازی شبکه به صورت مستقل از FC بوده و یا پیاده‌سازی شبکه به صورت مستقل از FC ترجیح داده می‌شود.

در تخمین مستقل از FC تمام محاسبات مربوط به الگوریتم منحصراً توسط گره‌های موجود در شبکه انجام می‌گیرد. به طور کلی طراحی الگوریتم برای این نوع از شبکه‌ها نسبت به شبکه‌های دارای FC مشکل‌تر است که علت آن ویژگی‌های خاص این شبکه مانند ثابت نبودن توپولوژی شبکه، متغیر بودن محیط و غیره می‌باشد. در طراحی الگوریتم برای شبکه‌های مستقل از FC دو اصل مشارکت بین گره‌ها و تطبیقی بودن الگوریتم به عنوان دو ابزار اساسی مورد پذیرش می‌باشند. با توجه به این مسئله اخیراً مفهوم تخمین تطبیقی توزیع شده (یا شبکه تطبیقی^۲) به عنوان روشی مناسب برای تخمین در شبکه‌های فاقد FC مد نظر قرار گرفته است. یک شبکه تطبیقی شامل مجموعه‌ای از عوامل متصل به یکدیگر با هدف حل مسائل استنباطی و تخمین توزیع شده به شیوه مشارکتی است [۲]. در تعریفی دقیق‌تر، به گروهی از گره‌های به هم متصل و توزیع شده در محیط که دارای ظرفیت و قابلیت پردازش اطلاعات و یادگیری هستند، به صورت نوعی تشکیل یک شبکه وفقی را می‌دهند. در چنین شبکه‌هایی گره‌ها می‌توانند به صورت مشارکتی و با استفاده از مبادله‌ی اطلاعات محلی به پردازش و بهینه‌سازی اطلاعات غیرمتمرکز بپردازند. کنش متقابل که موجب توزیع اطلاعات در تمامی شبکه می‌شود به گره‌ها امکان تطابق نسبت به تغییرات ویژگی‌های آماری داده‌ها یا تغییرات وضعیت جغرافیایی شبکه را می‌دهد.

شبکه‌های تطبیقی بر اساس استراتژی‌های افزایشی^۳ [۸-۳] و یا نفوذی^۴ [۹-۱۶] پیاده‌سازی می‌شوند (به شکل ۱ مراجعه شود). در استراتژی‌های افزایشی، داده‌ها درون یک حلقه (دور همیلتونی) که از تمامی گره‌های شبکه عبور می‌کند پردازش می‌شوند. بنابراین، گره‌ها تنها با همسایگان معینی از خود درون مسیر از قبل تعیین شده دایره‌ای، ارتباط دارند. تعیین چنین مسیری به خصوص برای شبکه‌های بزرگ اغلب بسیار دشوار است. همچنین، هر نوع خرابی گره یا لینک می‌تواند موجب اختلال در عملکرد شبکه شود.

همچنین هر یک از عناصر بردار \mathbf{y} نیز با رابطه زیر به دست می‌آیند:

$$y_j = \int_D h_j(\mathbf{x}) \mathcal{F}(\mathbf{x}) d\mathbf{x} \quad (5)$$

باید توجه داشت که در صورت داشتن بردار \mathbf{z}^o (یعنی جواب بهینه مسئله (۲))، میدان اسکالر در هر نقطه به صورت زیر تقریب زده می‌شود

$$\hat{\mathcal{F}}(x) = \mathbf{h}(x) \mathbf{z}^o = \sum_{\ell=1}^M h_\ell(x) [\mathbf{z}^o]_\ell \quad (6)$$

نکته مهم در این میان این است که چگونه می‌توان با داشتن اطلاعات محدود در گره‌های مختلف، میدان اسکالر را در نقاط مختلف تقریب زد. در بخش سوم نحوه استفاده از شبکه تطبیقی برای حل مسئله (۲) با استفاده از شبکه تطبیقی نفوذی شرح داده می‌شود.

۲-۲- معرفی شبکه تطبیقی نفوذی

به منظور توصیف شبکه‌های تطبیقی نفوذی شبکه‌ای شامل N گره را در نظر می‌گیریم. فرض می‌کنیم که هر یک از گره‌های موجود در شبکه (مانند گره k) در هر لحظه از زمان مانند n به اطلاعات $\{d_{k,n}, \mathbf{u}_{k,n}\}$ دسترسی دارد که در آن $d_{k,n}$ کمیت اسکالر اندازه‌گیری شده توسط گره و $\mathbf{u}_{k,n}$ بردار رگرسیون با ابعاد $1 \times M$ می‌باشد. با فرض مدل خطی، ارتباط بین $d_{k,n}$ و بردار $\mathbf{u}_{k,n}$ به صورت زیر می‌باشد:

$$d_{k,n} = \mathbf{u}_{k,n} \mathbf{w}^o + v_{k,n} \quad (7)$$

که در آن $v_{k,n}$ مؤلفه نویز مشاهده می‌باشد که به صورت فرآیند گوسی با میانگین صفر و واریانس $\sigma_{v,k}^2$ مدل می‌گردد. همچنین فرض می‌کنیم که هدف از پیاده‌سازی شبکه تخمین پارامتر برداری (با ابعاد $M \times 1$) \mathbf{w}^o با استفاده از اطلاعات موجود در گره‌های شبکه می‌باشند. کل اطلاعات موجود در گره‌های شبکه را می‌توان در ماتریس‌های \mathbf{d} و \mathbf{U} گردآوری نمود که در آن داریم:

$$\mathbf{d} \triangleq \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_N \end{bmatrix}_{N \times 1} \quad \mathbf{U} \triangleq \begin{bmatrix} \mathbf{u}_1 \\ \mathbf{u}_2 \\ \vdots \\ \mathbf{u}_N \end{bmatrix}_{N \times M} \quad (8)$$

با داشتن ماتریس‌های \mathbf{d} و \mathbf{U} مسئله مربوط به تخمین \mathbf{w}^o را می‌توان بر حسب مسئله بهینه‌سازی زیر بیان کرد:

$$\mathbf{w}^o = \arg \min_{\mathbf{w}} J(\mathbf{w}), \quad J(\mathbf{w}) \triangleq \sum_{k=1}^N E[(d_{k,n} - \mathbf{u}_{k,n} \mathbf{w})^2] \quad (9)$$

که در رابطه (۹) نماد $E[\cdot]$ معرف میانگین‌گیری آماری می‌باشد. پاسخ بهینه برای معادله (۹) در معادله زیر موسوم به معادله نرمال صدق می‌کند [۳]:

پیشنهادی بر مبنای MCC استخراج می‌گردد. کارایی الگوریتم پیشنهادی در یک سناریوی شبیه‌سازی تخمین میدان اسکالر مورد ارزیابی قرار گرفته و عملکرد آن با برخی از روش‌های موجود مورد مقایسه قرار می‌گیرد. نتایج به دست آمده از شبیه‌سازی‌های انجام گرفته نشان می‌دهد که در حضور گره‌های با نویز اندازه‌گیری بسیار بالا، الگوریتم پیشنهادی دارای کارایی به مراتب بهتری از الگوریتم مبتنی بر فیلتر LMS می‌باشد. از طرفی، پیچیدگی محاسباتی الگوریتم پیشنهادی نیز مشابه الگوریتم LMS می‌باشد که این موضوع به کارگیری الگوریتم پیشنهادی را برای پیاده‌سازی در شبکه‌های سنسوری بی‌سیم مناسب می‌سازد.

در ادامه مقاله ابتدا در بخش دوم به معرفی میدان اسکالر پرداخته و سپس مفهوم شبکه تطبیقی نفوذی به اختصار شرح داده می‌شود. در بخش سوم نحوه حل مسئله تخمین میدان اسکالر با استفاده از شبکه تطبیقی نفوذی مورد بررسی قرار گرفته و الگوریتم پیشنهادی در بخش چهارم معرفی می‌گردد. در بخش پنجم نتایج حاصل از شبیه‌سازی ارائه شده و در بخش ششم نتایج اصلی به دست آمده از مقاله بیان می‌گردند.

۲- معرفی میدان اسکالر و شبکه تطبیقی نفوذی

۱-۱- میدان اسکالر

ناحیه (محدوده) جغرافیایی مانند $D \subset \mathbb{R}^2$ و میدان اسکالر مربوط به آن یعنی \mathcal{F} را در نظر می‌گیریم. فرض می‌کنیم که میدان اسکالر \mathcal{F} یک زیرمجموعه از فضای خطی $\mathcal{C}(D)$ (یعنی $\mathcal{F} \in \mathcal{C}(D)$) باشد که در آن فضای خطی شامل تمام توابع پیوسته از D به مجموعه اعداد حقیقی \mathbb{R} می‌باشد. برای فضای خطی $\mathcal{C}(D)$ ، مجموعه \mathcal{B} به عنوان مجموعه تشکیل‌دهنده توابع پایه این فضا تعریف می‌شود؛ یعنی:

$$\mathcal{B} = \{h_\ell \in \mathcal{C}(D)\}, \quad \ell = 1, 2, \dots, M \quad (1)$$

که در آن $\{h_\ell\}$ ، $\ell = 1, 2, \dots, M$ توابع مستقل خطی می‌باشند. همچنین، برای هر نقطه از D مانند $\mathbf{x} \in D$ ، بردار سطری $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_M(\mathbf{x})]$ بهترین تقریب برای میدان \mathcal{F} در نقطه \mathbf{x} (بر حسب معیار کم‌ترین مربعات) را می‌توان با استفاده از مسئله زیر بیان کرد:

$$\arg \min_{\mathbf{z}} J_1(\mathbf{z}), \quad J_1(\mathbf{z}) \triangleq \int_D (\mathcal{F}(\mathbf{x}) - \mathbf{h}(\mathbf{x})\mathbf{z})^2 d\mathbf{x} \quad (2)$$

جواب معادله فوق، \mathbf{z}^o در معادله نرمال زیر صدق می‌کند:

$$\mathbf{G}\mathbf{z}^o = \mathbf{y} \quad (3)$$

که در آن هر یک از عناصر ماتریس \mathbf{G} مانند عنصر $[\mathbf{G}]_{i,j}$ به صورت زیر داده می‌شود:

$$[\mathbf{G}]_{i,j} = \int_D h_i(x) h_j(x) dx \quad (4)$$

باید به این نکته توجه داشت که علاوه بر LMS، از سایر فیلترهای تطبیقی نظیر RLS، NLMS و غیره نیز در ساختار شبکه تطبیقی می‌توان استفاده نمود. در [۲، ۳۰] شبکه‌های تطبیقی که در ساختار آن‌ها از سایر فیلترهای تطبیقی (غیر از LMS) استفاده شده معرفی شده و نحوه عملکرد آن‌ها مورد مقایسه قرار گرفته است.

۳- الگوریتم پیشنهادی

در این بخش ابتدا نحوه حل مسئله تخمین میدان اسکالر با استفاده از شبکه تطبیقی نفوذی مبتنی بر LMS شرح داده شده و در ادامه الگوریتم تخمین مقاوم پیشنهادی ارائه می‌گردد.

۳-۱- تخمین میدان اسکالر با استفاده از شبکه تطبیقی

فرض می‌کنیم که تعداد N سنسور به‌طور تصادفی در ناحیه \mathcal{D} توزیع شده و میدان اسکالر توسط آن‌ها رصد می‌گردد. همچنین موقعیت هر سنسور در لحظه n به‌صورت $\mathbf{p}_{k,n} \in \mathcal{D}$ نمایش داده می‌شود. در این صورت هر گره مانند k در هر لحظه از زمان مانند n یک مشاهده نویزی از میدان اسکالر به‌صورت زیر خواهد داشت:

$$d_{k,n} = \mathcal{F}(\mathbf{p}_{k,n}) + v_{k,n} \quad (16)$$

که در آن $v_{k,n}$ مؤلفه نویز مشاهده می‌باشد. همچنین بردار رگرسیون برای گره k در لحظه n را می‌توان به‌صورت زیر در نظر گرفت:

$$\mathbf{u}_{k,n} = \mathbf{h}(\mathbf{p}_{k,n}) = [h_1(\mathbf{p}_{k,n}), h_2(\mathbf{p}_{k,n}), \dots, h_M(\mathbf{p}_{k,n})] \quad (17)$$

بنابراین هر گره از شبکه مانند k در هر لحظه از زمان مانند n به اطلاعاتی به فرم $\{d_{k,n}, \mathbf{u}_{k,n}\}$ دسترسی دارد. هدف از به‌کارگیری شبکه تخمین بردار \mathbf{z}^o با استفاده از اطلاعات موجود در گره‌های شبکه می‌باشد.

در ادامه نشان داده می‌شود که شبکه تطبیقی مبتنی بر استراتژی نفوذی (الگوریتم ارائه شده در (۱۵)) را می‌توان با در دست داشتن اطلاعات موجود در گره‌ها به‌صورت (۱۶) و (۱۷) برای تخمین میدان اسکالر استفاده نمود. بدین منظور ابتدا باید به این نکته توجه داشت که تابع هزینه مورد استفاده در استخراج شبکه تطبیقی نفوذی (یعنی رابطه (۹)) به فرم تابع هزینه بیان شده در رابطه (۲) نمی‌باشد. لذا مسئله‌ای که در ابتدا باید مورد بررسی قرار گیرد این است که آیا مسئله (۹) فرم دیگری از مسئله تخمین میدان اسکالر بیان شده با رابطه (۲) بیان می‌باشد؟ برای پاسخ به این پرسش مجدداً تابع هزینه (۹) را در نظر می‌گیریم. با جایگزین کردن مقادیر $d_{k,n}$ و $\mathbf{u}_{k,n}$ از روابط (۱۶) و (۱۷) در تابع هزینه (۹) داریم:

$$\mathbf{w}^o = \left(\sum_{k=1}^N \mathbf{R}_{u,k} \right)^{-1} \left(\sum_{k=1}^N \mathbf{r}_{du,k} \right) \quad (10)$$

که در آن داریم:

$$\mathbf{R}_{u,k} = E[\mathbf{u}_{k,n}^* \mathbf{u}_{k,n}] \quad (11)$$

$$\mathbf{r}_{du,k} = E[\mathbf{u}_{k,n}^* d_{k,n}] \quad (12)$$

که در روابط فوق (*) معرف عملگر هرمیتی می‌باشد. به‌کارگیری معادله (۱۰) مستلزم در دسترس بودن اطلاعات آماری $\{\mathbf{R}_{u,k}, \mathbf{r}_{du,k}\}$ در تمام گره‌های شبکه می‌باشد که در عمل چنین اطلاعاتی در دسترس نیست و یا حتی در صورت در دسترس بودن، نیازمند به تبادل گسترده اطلاعات مابین گره‌های شبکه به‌منظور فراهم نمودن اطلاعات هر گره در سایر گره‌ها می‌باشد. همان‌طور که در مقدمه اشاره شد شبکه‌های تطبیقی به عنوان استراتژی‌های کارآمد برای حل مسائلی به فرم مسئله بیان شده در رابطه (۹) می‌باشد. در ادامه نحوه حل مسئله (۹) با استفاده از شبکه تطبیقی نفوذی شرح داده می‌شود.

در شبکه‌های تطبیقی با مشارکت نفوذی هر گره مانند گره k از تخمین‌های جمع‌آوری شده از سایر گره‌های مجاور برای داشتن برآوردی از تخمین‌های گره‌های مجاور استفاده می‌نماید. این فرآیند را می‌توان به‌صورت زیر بیان کرد:

$$\mathbf{g}_{k,n-1} = \sum_{\ell \in \mathcal{N}_k} c_{k,\ell} \mathbf{w}_{\ell,n-1} \quad (13)$$

که در آن \mathcal{N}_k معرف مجموعه همسایگان گره k بوده و $c_{k,\ell} \in \mathbb{R}$ ضرایبی هستند که برای ترکیب تخمین‌های به دست آمده از گره‌های همسایه k مورد استفاده قرار می‌گیرند. همچنین برداری است که نشان‌دهنده تخمین گره k از بردار \mathbf{w}^o در لحظه n می‌باشد. پس از محاسبه $\mathbf{g}_{k,n-1}$ ، گره k از آن و نیز از اطلاعات موجود در خود گره یعنی $\{d_{k,n}, \mathbf{u}_{k,n}\}$ برای به‌روز کردن تخمین $\mathbf{w}_{k,n}$ استفاده می‌نماید. در صورت استفاده از فیلتر تطبیقی LMS رابطه به‌روز کردن تخمین در سنسور k به‌صورت زیر خواهد بود:

$$\mathbf{w}_{k,n} = \mathbf{g}_{k,n-1} + \mu_k \mathbf{u}_{k,n}^* (d_{k,n} - \mathbf{u}_{k,n} \mathbf{g}_{k,n-1}) \quad (14)$$

بنابراین رابطه به‌روز کردن تخمین محلی در هر گره در شبکه تطبیقی نفوذی بر مبنای فیلتر تطبیقی LMS را می‌توان با رابطه زیر بیان نمود:

$$\begin{cases} \mathbf{w}_{k,0} = \mathbf{0} \\ \mathbf{g}_{k,n-1} = \sum_{\ell \in \mathcal{N}_k} c_{k,\ell} \mathbf{w}_{\ell,n-1} \\ \mathbf{w}_{k,n} = \mathbf{g}_{k,n-1} + \mu_k \mathbf{u}_{k,n}^* (d_{k,n} - \mathbf{u}_{k,n} \mathbf{g}_{k,n-1}) \end{cases} \quad (15)$$

$$\kappa_{\omega}(x, y) = \frac{1}{\sqrt{2\pi\omega}} \exp\left(-\frac{(x-y)^2}{2\omega^2}\right) \quad (۲۳)$$

رابطه (۲۲) نشان می‌دهد که به دلیل وجود عملگر میانگین آماری، محاسبه correntropy نیازمند داشتن تابع چگالی مشترک متغیرهای تصادفی X و Y می‌باشد که فرض در دسترس بودن آن برای بسیاری از کاربردهای واقعی چندان فرض مناسبی نیست. از طرفی، با توجه به اینکه در بیشتر مواقع دنباله نمونه‌های مشترک متغیرهای تصادفی X و Y به صورت $\{x_t, y_t\}, t=1, 2, \dots, L$ در دسترس می‌باشند لذا به جای رابطه (۲۲) می‌توان از رابطه تقریبی زیر استفاده کرد:

$$\hat{C}(X, Y) = \frac{1}{L} \sum_{t=1}^L \kappa_{\omega}(x_t - y_t) \quad (۲۴)$$

برای تعریف تابع هزینه مورد نظر در این مقاله موارد زیر را در نظر می‌گیریم:

۱. چنانچه از کمیت correntropy به عنوان تابع هزینه در کاربرد مبتنی بر فیلتر تطبیقی استفاده شود، شکل کلی تابع هزینه به صورت مسئله بهینه‌سازی زیر خواهد بود [۲۸]:

$$\arg \max J_c \quad \text{where } J_c \triangleq \hat{C}(d_t, y_t) \quad (۲۵)$$

که در آن d و y به ترتیب معرف پاسخ مطلوب و خروجی فیلتر تطبیقی می‌باشند.

۲. تابع هزینه مورد استفاده برای کاربرد مورد نظر نه تنها باید مقاوم بودن الگوریتم نهایی را تضمین نماید، بلکه در آن مشارکت بین گره‌ها نیز دخالت داده شود.

با توجه به این نکات تابع هزینه مورد استفاده در هر گره شبکه مانند گره k به صورت زیر تعریف می‌شود:

$$\arg \max_{\mathbf{w}} J_p(\mathbf{w}) \quad (۲۶)$$

که در آن $J_p(\mathbf{w})$ به صورت زیر تعریف می‌گردد:

$$J_p(\mathbf{w}) = \left(\frac{1}{L\sqrt{2\pi\omega}} \sum_{j=i-L+1}^i \exp\left(\frac{-(d_{k,j} - \mathbf{u}_{k,j}\mathbf{w})^2}{2\sigma^2}\right) - \sum_{l \in \mathcal{N}_k} c_{k,l} \|\mathbf{w} - \mathbf{q}_l\| \right) \quad (۲۷)$$

که در آن جمله اول برای تضمین مقاوم بودن الگوریتم و جمله دوم برای اثر دادن مشارکت گره‌ها در حل مسئله تخمین به کار گرفته شده‌اند. باید توجه شود که در جمله دوم مقادیر $\{\mathbf{q}_l\}, l \in \mathcal{N}_k$ تخمین سراسری گره مجاور l از بردار \mathbf{w}^0 می‌باشند. برای به دست آوردن یک الگوریتم غیرمتمرکز که برای پیاده‌سازی بر روی شبکه‌های سنسوری بی‌سیم مناسب باشد، ابتدا با استفاده از روش تندترین صعود یک راه‌حل تکرارشونده^۹ برای حل مسئله بهینه‌سازی فوق به صورت زیر حاصل می‌گردد:

$$\mathbf{w}_{k,n} = \mathbf{w}_{k,n-1} + \eta \nabla_{\mathbf{w}_{k,n-1}} [J_p(\mathbf{w})] \quad (۲۸)$$

$$\begin{aligned} J_2(\mathbf{w}) &= \sum_{k=1}^N E[(d_{k,n} - \mathbf{u}_{k,n}\mathbf{w})^2] \\ &= \sum_{k=1}^N E[(\mathcal{F}(\mathbf{p}_{k,n}) + v_{k,n} - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2] \\ &= \sum_{k=1}^N E[(\mathcal{F}(\mathbf{p}_{k,n}) - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2] + \sum_{k=1}^N E[v_{k,n}^2] \\ &\quad - 2 \sum_{k=1}^N E[(\mathcal{F}(\mathbf{p}_{k,n}) - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2 v_{k,n}] \\ &= \sum_{k=1}^N E[(\mathcal{F}(\mathbf{p}_{k,n}) - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2] + \sum_{k=1}^N \sigma_{v,k}^2 \end{aligned} \quad (۱۸)$$

با ضرب $\frac{|D|}{N}$ در $J_2(\mathbf{w})$ تابع هزینه جدید به صورت زیر خواهد بود:

$$J_3(\mathbf{w}) = \frac{|D|}{N} \sum_{k=1}^N E[(\mathcal{F}(\mathbf{p}_{k,n}) - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2] + \frac{|D|}{N} \sum_{k=1}^N \sigma_{v,k}^2 \quad (۱۹)$$

از طرفی، با فرض اینکه سنسورهای شبکه به صورت تصادفی در ناحیه توزیع شده باشند آنگاه می‌توان نحوه توزیع مکانی آن‌ها را به صورت یک توزیع یکنواخت مدل نمود. در این حالت از آنجایی که برای هر تابع مانند $f \in \mathcal{C}(D)$ تقریب زیر معتبر است [۳۱]:

$$\int_D f(\mathbf{x}) d\mathbf{x} \approx \frac{|D|}{N} \sum_{k=1}^N f(\mathbf{x}_k) \quad (۲۰)$$

با قرار دادن $f(\mathbf{x}) = E[(\mathcal{F}(\mathbf{p}_{k,n}) - \mathbf{h}_{k,n}(\mathbf{p}_{k,n})\mathbf{w})^2]$ می‌توان دریافت که جمله اول در رابطه (۱۹) تقریبی از تابع هزینه داده‌شده در رابطه (۲) می‌باشد، یعنی:

$$J_3(\mathbf{w}) \approx J_1(\mathbf{w}) + \frac{|D|}{N} \sum_{k=1}^N \sigma_{v,k}^2 \quad (۲۱)$$

از آنجا که جمله دوم در رابطه (۱۹) به مقدار \mathbf{w} بستگی ندارد لذا مینیمم کردن $J_3(\mathbf{w})$ معادل مینیمم کردن تابع $J_1(\mathbf{w})$ می‌باشد. بنابراین با در نظر گرفتن مطالب فوق می‌توان نتیجه گرفت که الگوریتم ارائه‌شده در (۱۵) را می‌توان با تعاریف داده‌ها به صورت (۱۶) و (۱۷) برای تخمین میدان اسکالر به کار برد.

۳-۲- الگوریتم مقاوم پیشنهادی


همان‌طور که در مقدمه اشاره شد الگوریتم مقاوم پیشنهادی در این مقاله بر اساس شبکه تطبیقی نفوذی و تابع هزینه مبتنی بر correntropy می‌باشد. برای متغیرهای تصادفی X و Y کمیت correntropy به صورت زیر تعریف می‌گردد:

$$C(X, Y) = E[\kappa_{\omega}(X - Y)] \quad (۲۲)$$

که در آن $\kappa_{\omega}(\cdot)$ تابع هسته (کرنل) Mercer با پارامتر (عرض هسته) ω می‌باشد. در این مقاله تابع هسته گاوسی مورد استفاده قرار خواهد گرفت که رابطه آن به صورت زیر می‌باشد:

۴- شبیه‌سازی

در این بخش کارایی الگوریتم پیشنهادی در یک سناریوی شبیه‌سازی تخمین میدان اسکالر مورد ارزیابی قرار گرفته و عملکرد آن با برخی از روش‌های موجود مورد مقایسه قرار می‌گیرد. بدین منظور شبکه‌ای متشکل از ۱۰۰ گره که در فضای به صورت $D \in [0,1] \times [0,1]$ تصادفی توزیع شده‌اند در نظر گرفته می‌شود. توپولوژی شبکه به گونه‌ای است که گره‌های بافاصله کم‌تر از 0.2 واحد با هم در ارتباط هستند. در شکل ۲ توپولوژی شبکه مورد استفاده در شبیه‌سازی نشان داده شده است.



شکل ۲: توپولوژی شبکه استفاده‌شده برای انجام شبیه‌سازی عملکرد الگوریتم پیشنهادی

فرض می‌شود که میدان اسکالر مورد نظر به صورت

$$\mathcal{F}(x_1, x_2) = \frac{0.7}{\sqrt{1 + 20(x_1 - 0.15)^2 + 20(x_2 - 0.15)^2}} + \frac{1}{\sqrt{1 + 15(x_1 - 0.7)^2 + 15(x_2 - 0.7)^2}} \quad (33)$$

در ناحیه $D \in [0,1] \times [0,1]$ توزیع شده است. مجموعه تشکیل‌دهنده توابع پایه این فضا به ازای $M = 36$ به صورت زیر تعریف می‌گردد:

$$h_\ell(\mathbf{x}) = \exp(-20 \|\mathbf{x} - c_\ell\|^2) \quad (34)$$

که در آن نقاط c_ℓ به فاصله 0.2 واحد (مطابق شکل ۳) از هم قرار دارند. برای مشاهدات گرہها از مدل خطی (۱۶) استفاده نموده و فرض می‌کنیم مؤلفه نویز مشاهدات در هر گره در حالت کلی به صورت زیر بیان می‌گردد:

$$v_{k,n} = \delta_{k,n}^{(1)} + b_{k,n} \delta_{k,n}^{(2)} \quad (35)$$

که در آن $\delta_{k,n}^{(1)}$ و $\delta_{k,n}^{(2)}$ مؤلفه‌های نویز مستقل از هم هستند که دارای توزیع گوسی با میانگین صفر و واریانس‌های $\sigma_{v,k}^2 = 2$ و $\sigma_{v,k}^2 = 10^{-3}$ می‌باشند. همچنین $b_{k,n}$ بیان‌گر یک دنباله تصادفی با توزیع برنولی با توزیع احتمال $\Pr\{b_{k,n} = 1\} = P_1$, $\Pr\{b_{k,n} = 0\} = 1 - P_1$ می‌باشد. فرض می‌کنیم که ۱۰ گره از شبکه دارای مشاهدات بسیار پایین

که در آن $\eta > 0$ بوده و $\nabla_{\mathbf{w}_{k,n-1}} [J_p(\mathbf{w})]$ بیانگر گرادیان از تابع $J_p(\mathbf{w})$ بر حسب بردار $\mathbf{w}_{k,n-1}$ می‌باشد. برای گرادیان تابع $J_p(\mathbf{w})$ به‌ازای $L=1$ و $\mathbf{w}_{k,n}$ داریم:

$$\mathbf{w}_{k,n} = \mathbf{w}_{k,n-1} + \frac{\eta}{2\sigma^2} \mathbf{u}_{k,n}^* \exp\left(\frac{-e_{k,n}^2}{2\sigma^2}\right) e_{k,n} + \eta \sum_{l \in \mathcal{N}_k} c_{k,l} \|\mathbf{w}_{k,n-1} - \mathbf{q}_l\| \quad (29)$$

که در آن $e_{k,n}$ به صورت $e_{k,n} = d_{k,n} - \mathbf{u}_{k,n} \mathbf{w}_{k,n-1}$ تعریف می‌شود. برای اینکه رابطه بازگشتی فوق برای پیاده‌سازی بر روی شبکه تطبیقی نفوذی با استراتژی نفوذی باشد تغییرات زیر را در رابطه فوق اعمال می‌کنیم:

۱. با معرفی $\theta_{k,n}$ به عنوان متغیر واسطه^۱ (تخمین محلی گره مجاور) رابطه (۲۹) به فرم معادل زیر بیان می‌شود:

$$\theta_{k,n} = \mathbf{w}_{k,n-1} + \frac{\eta}{2\sigma^2} \mathbf{u}_{k,n}^* \exp\left(\frac{-e_{k,n}^2}{2\sigma^2}\right) e_{k,n} \quad (30)$$

$$\mathbf{w}_{k,n} = \theta_{k,n} + \eta \sum_{l \in \mathcal{N}_k} c_{k,l} \|\mathbf{w}_{k,n-1} - \mathbf{q}_l\|$$

باید به این نکته توجه داشت که به لحاظ پیاده‌سازی، روابط (۲۹) و (۳۰) کاملاً یکسان هستند.

۲. در رابطه به دست آمده فوق متغیر واسطه $\theta_{k,n}$ جایگزین \mathbf{q}_l می‌گردد:

$$\theta_{k,n} = \mathbf{w}_{k,n-1} + \frac{\eta}{2\sigma^2} \mathbf{u}_{k,n}^* \exp\left(\frac{-e_{k,n}^2}{2\sigma^2}\right) e_{k,n} \quad (31)$$

$$\mathbf{w}_{k,n} = \theta_{k,n} + \eta \sum_{l \in \mathcal{N}_k} c_{k,l} \|\mathbf{w}_{k,n-1} - \theta_{l,n}\|$$

۳. سرانجام در معادله $\sum_{l \in \mathcal{N}_k} c_{k,l} \|\mathbf{w}_{k,n-1} - \theta_{l,n}\|$ از رابطه فوق $\mathbf{w}_{k,n-1}$ را با متغیر واسطه $\theta_{k,n}$ جایگزین نموده و رابطه به‌روزرسانی زیر حاصل می‌گردد:

$$\theta_{k,n} = \mathbf{w}_{k,n-1} + \frac{\eta}{2\sigma^2} \mathbf{u}_{k,n}^* \exp\left(\frac{-e_{k,n}^2}{2\sigma^2}\right) e_{k,n} \quad (32)$$

$$\mathbf{w}_{k,n} = \theta_{k,n} + \eta \sum_{l \in \mathcal{N}_k} c_{k,l} \|\theta_{k,n-1} - \theta_{l,n}\|$$

باید به این نکته توجه داشت که در مقایسه با الگوریتم مبتنی بر LMS، الگوریتم پیشنهادی نیازمند محاسبه جمله اضافی


$\exp\left(\frac{-e_{k,n}^2}{2\sigma^2}\right)$ همچنین حاصل ضرب آن با جمله $e_{k,n}$ می‌باشد. از

آنجایی که محاسبات یادشده چندان پیچیده نیستند، لذا همان‌طور که در [۲۷] اشاره شده است، بار محاسباتی الگوریتم‌های مبتنی بر correntropy در رده الگوریتم LMS می‌باشند.

در ادامه به بررسی عملکرد الگوریتم پیشنهادی پرداخته می‌شود.

$$c_{k,l} = \begin{cases} \frac{1}{|\mathcal{N}_k|} & l \in \mathcal{N}_k \\ 0 & l \notin \mathcal{N}_k \end{cases} \quad (38)$$

که در آن \mathcal{N}_k نشان دهنده تعداد گره‌های مجاور گره k می‌باشد. در شکل ۴ منحنی MSD متوسط شبکه برای الگوریتم‌های مورد نظر نشان داده شده است. همان‌طور که از شکل ۴ مشخص است الگوریتم پیشنهادی دارای کارایی بهتری نسبت به سایر روش‌های مورد مقایسه است. در شکل ۵ میدان اسکالر تخمین زده شده توسط الگوریتم پیشنهادی نشان داده شده است.



شکل ۵: میدان اسکالر تخمین زده شده توسط الگوریتم پیشنهادی

با مقایسه شکل ۵ با شکل ۳ (که در آن میدان اسکالر مورد نظر نمایش داده شده است) می‌توان دریافت که حتی با وجود تعدادی از گره‌های شبکه که تنها به داده‌های با کیفیت بسیار پایین دسترسی داشته‌اند، الگوریتم پیشنهادی توانسته است تخمین خوبی از میدان اسکالر مورد نظر فراهم سازد. در اینجا باید به این نکته اشاره شود که در صورتی که تمام گره‌های شبکه دارای کیفیت مشاهدات مناسبی باشند، عملکرد الگوریتم پیشنهادی تقریباً مشابه الگوریتم LMS خواهد بود.


۵- نتیجه‌گیری

در این مقاله، الگوریتمی مبتنی بر شبکه تطبیقی نفوذی برای تخمین مقاوم میدان اسکالر با استفاده از مشاهدات شبکه سنسوری بی‌سیم پیشنهاد گردید. مقاوم بودن الگوریتم پیشنهادی بدین معنی است که چنانچه تعدادی از گره‌های شبکه به داده‌های با کیفیت بسیار پایین ناشی از نویز ضربه‌ای دسترسی داشته باشند الگوریتم بتواند تخمین مناسبی از میدان اسکالر ارائه دهد. برای داشتن چنین الگوریتمی، ابتدا مسئله تخمین میدان اسکالر به وسیله شبکه سنسوری به صورت یک مسئله بهینه‌سازی با تابع هزینه مبتنی بر MCC بیان شده و در ادامه الگوریتمی برای حل مسئله به صورت توزیع شده و مبتنی بر شبکه تطبیقی نفوذی ارائه شده است. برای ارزیابی الگوریتم، عملکرد آن بر روی یک سناریوی تخمین میدان اسکالر شبیه‌سازی شده و با برخی از روش‌های موجود مقایسه گردید. نتایج به دست آمده نشان دهنده کارایی مناسب الگوریتم پیشنهادی برای کاربرد مورد نظر است.

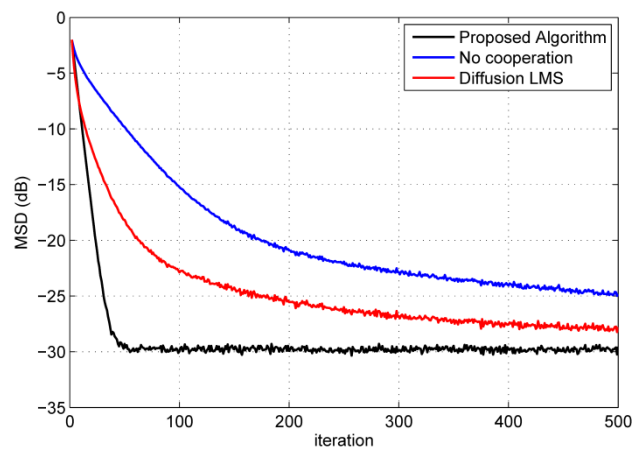
ناشی از نویز ضربه‌ای هستند به گونه‌ای که برای مؤلفه نویز مشاهدات آن‌ها $\Pr\{b_{k,n} = 1\} = 0.2$ بوده و برای سایر گره‌ها $\Pr\{b_{k,n} = 1\} = 0$ می‌باشد.

الگوریتم‌های مورد بررسی شامل الگوریتم نفوذی LMS (رابطه (۱۵))، الگوریتم پیشنهادی و الگوریتم غیرمشارکتی مبتنی بر LMS است که رابطه به روزرسانی در هر گره در آن به صورت زیر بیان می‌شود:

$$\mathbf{w}_{k,n} = \mathbf{w}_{k,n-1} + \mu_k \mathbf{u}_{k,n}^* (d_{k,n} - \mathbf{u}_{k,n} \mathbf{w}_{k,n-1}) \quad (36)$$



شکل ۳: میدان اسکالر که شبکه سنسوری برای تخمین آن استفاده شده است (سمت چپ)، نحوه توزیع نقاط c_l (در رابطه (۳۳)) که به فاصله 0.2 واحد از هم قرار دارند



شکل ۴: منحنی MSD متوسط شبکه برای الگوریتم‌های مختلف

برای مقایسه الگوریتم‌های مختلف از معیار متوسط MSD شبکه استفاده می‌کنیم که به صورت زیر تعریف می‌شود:

$$\text{MSD} = \frac{1}{N} \sum_{k=1}^N E \left[\|\mathbf{z}^o - \mathbf{w}_{k,n}\|^2 \right] \quad (37)$$

پارامترهای مربوط به ضریب گام برای الگوریتم‌های مختلف به گونه‌ای تنظیم شده‌اند که همه الگوریتم‌ها دارای سرعت همگرایی اولیه یکسانی باشند. برای ضرایب ترکیب الگوریتم LMS نفوذی و همچنین الگوریتم پیشنهادی از قانون نزدیک‌ترین همسایه استفاده شده است که در آن داریم:

- [14] S. Jung, J. H. Seo, and P. Park, "A variable step-size diffusion normalized least-mean-square algorithm with a combination method based on mean-square deviation," *Circuits, Systems, and Signal Processing*, vol. 34, no. 10, pp. 3291–3304, 2015.
- [15] D. Mandic and V. S. L. Goh, *Complex Valued Nonlinear Adaptive Filters: Noncircularity, Widely Linear and Neural Models*, Wiley Publishing, 2009.
- [16] C. K. Yu, M. V. D. Schaar, and A. H. Sayed, "Information-sharing over adaptive networks with self-interested agents," *IEEE Trans. Signal and Information Processing over Networks*, vol. 1, no. 1, pp. 2–19, 2015.
- [17] A. Khalili, M. A. Tinati, A. Rastegarnia, and J. A. Chambers, "Steady-state analysis of diffusion LMS adaptive networks with noisy links," *IEEE Trans. Signal Process.*, vol. 60, no. 2, pp. 974–979, 2012.
- [18] X. Zhao, S. Y. Tu, and A. H. Sayed, "Diffusion adaptation over networks under imperfect information exchange and non-stationary data," *IEEE Trans. on Signal Process.*, vol. 60, no. 7, pp. 3460–3475, 2012.
- [19] A. Rastegarnia, W. M. Bazzi, A. Khalili, and J. A. Chambers, "Diffusion adaptive networks with imperfect communications: link failure and channel noise," *IET Signal Processing*, vol. 8, no. 1, pp. 59–66, 2014.
- [20] A. H. Sayed, "Adaptation, learning, and optimization over networks," *Foundations and Trends in Machine Learning*, vol. 7, no.4-5, pp 311-801, 2014.
- [21] H. Zhang, J. Moura, and B. Krogh, "Dynamic field estimation using wireless sensor networks: Tradeoffs between estimation error and communication cost," *IEEE Trans. Signal Process.*, vol. 57, no. 6, pp. 2383–2395, 2009.
- [22] P. Braca, S. Marano, V. Matta, "Enforcing consensus while monitoring the environment in wireless sensor networks," *IEEE Trans. Signal Process.*, vol. 56, no. 7, pp.3375–3380, 2008.
- [23] Y. M. Lu, M. Vetterli, "Spatial super-resolution of a diffusion field by temporal oversampling," *In IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 2249–2252, 2009.
- [24] I. Dokmanic, J. Ranieri, A. Chebira, M. Vetterli, "Sensor networks for diffusion fields: detection of sources in space and time," *In 49th Allerton Conference on Communication, Control, and Computing*, pp. 1552–1558, 2011.
- [25] J. Ranieri, Y. Lu, A. Chebira, M. Vetterli, "Sampling and reconstructing diffusion fields with localized sources," *In Proc. IEEE International Conference on Acoustics, Speech, And Signal Processing*, pp. 4016–4019, 2011.
- [26] N. Antonello, T. V. Waterschoot, M. Moonen, P. A. Naylor, "Source localization and signal reconstruction in a reverberant field using the FDTD method," *In Proceedings of the 22nd European on Signal Processing Conference*, pp. 301–305, 2014.
- [27] A. Singh and J. Principe, "Using correntropy as a cost function in linear adaptive filters," *In International Joint Conference on Neural Networks*, pp. 2950–2955, 2009.
- [28] S. Zhao, B. Chen, and J. C. Principe, "Kernel adaptive filtering with maximum correntropy criterion," *in Int. Joint Conf. Neural Networks (IJCNN)*, pp. 2012–2017, 2011.
- [29] W. M. Bazzi, A. Rastegarnia, A. Khalili, "A robust diffusion adaptive network based on the maximum correntropy criterion," *24th International conference on computer communication and networks (ICCCN)*, 2015.
- در الگوریتم پیشنهادی کانال بین گره‌های شبکه ایده‌آل (بدون خطا) فرض شده است. چنین فرض می‌تواند در بسیاری از کاربردها معتبر نباشد [۳۲]. در کارهای آینده، مسئله تخمین مقاوم میدان اسکالر با استفاده از یک شبکه سنسوری بی‌سیم در حالت واقعی‌تری که کانال بین گره‌ها نیز غیرایده‌آل باشند مورد بررسی قرار خواهد گرفت. همچنین به کارگیری الگوریتم پیشنهادی در سایر کاربردهای مرتبط با پردازش توزیع‌شده از جمله در شبکه‌های حسگر بصری [۳۳] مورد بررسی قرار خواهد گرفت.

مراجع

- [1] D. Puccinelli and M. Haenggi, "Wireless sensor networks: applications and challenges of ubiquitous sensing," *IEEE Circuits and Systems Magazine*, vol. 5, no. 3, pp. 19–31, 2005.
- [2] A. H. Sayed, "Adaptive networks," *Proceedings of the IEEE*, vol. 102, no. 4, pp. 460–497, 2014.
- [3] C. G. Lopes and A. H. Sayed, "Incremental adaptive strategies over distributed networks," *IEEE Trans. Signal Processing*, vol. 55, no. 8, pp. 4064–4077, 2007.
- [4] L. Li, J. A. Chambers, C. G. Lopes, and A. H. Sayed, "Distributed estimation over an adaptive incremental network based on the affine projection algorithm," *IEEE Trans. Signal Process.*, vol. 58, no. 1, pp. 151–164, 2010.
- [5] A. Rastegarnia, M. A. Tinati, and A. Khalili, "Performance analysis of quantized incremental LMS algorithm for distributed adaptive estimation," *Signal Processing*, vol. 90, no. 8, pp. 2621–2627, 2010.
- [6] M. Saeed and A. U. H. Sheikh, "A new LMS strategy for sparse estimation in adaptive networks," *in IEEE 23rd International Symposium on Personal Indoor and Mobile Radio Communications (PIMRC)*, pp. 1722–1733, 2012.
- [7] A. Khalili, A. Rastegarnia, W. Bazzi, and Z. Yang, "Derivation and analysis of incremental augmented complex least mean square algorithm," *IET Signal Processing*, vol. 9, no. 4, pp. 312–319, 2015.
- [8] G. Azarnia and M. Tinati, "Steady-state analysis of the deficient length incremental LMS adaptive networks," *Circuits, Systems, and Signal Processing*, vol. 34, no.9, pp. 2893–2910, 2015.
- [9] O. Gharehshiran, V. Krishnamurthy, and G. Yin, "Distributed energy-aware diffusion least mean squares: Game-theoretic learning," *IEEE Journal of Selected Topics in Signal Processing*, vol. 7, no. 5, pp. 821–8836, 2013.
- [10] P. Di Lorenzo and S. Barbarossa, "Distributed least mean squares strategies for sparsity-aware estimation over Gaussian Markov random fields," *In IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 5472–5476, 2014.
- [11] J. Chen and A. H. Sayed, "Diffusion adaptation strategies for distributed optimization and learning over networks," *IEEE Trans. Signal Process.*, vol. 60, no. 8, pp. 4289–4305, 2012.
- [12] C. Li, P. Shen, Y. Liu, and Z. Zhang, "Diffusion information theoretic learning for distributed estimation over network," *IEEE Transactions on Signal Processing*, vol. 61, no. 16, pp. 4011–4024, 2013.
- [13] R. Arablouei, S. Werner, Y. F. Huang, and K. Dogancay, "Distributed least mean-square estimation with partial diffusion," *IEEE Transactions on Signal Processing*, vol. 62, no. 2, pp. 472–484, 2014.

توزیع شده افزایشی طول متغیر»، مجله مهندسی برق دانشگاه تبریز، دوره ۴۵، شماره ۳، صفحات ۱-۱۵، ۱۳۹۴.

[۳۳] سیدهادی اقدسی و مقصود عباس پور، «الگوریتم توزیع شده جهت فراهم آوردن پوشش چندجانبه از هدف در شبکه‌های حسگر بصری»، مجله مهندسی برق دانشگاه تبریز، دوره ۴۲، شماره ۲، صفحات ۵۳-۶۳، ۱۳۹۱.

- [30] A. H. Sayed, S.-Y. Tu, J. Chen, X. Zhao, and Z. J. Towfic, "Diffusion strategies for adaptation and learning over networks," *IEEE Signal Processing Magazine*, vol. 30, no. 3, pp. 155-171, May 2013.
- [31] A. Papoulis and S. Pillai, *Probability, Random Variables, and Stochastic Processes*, 4th Edition, McGraw-Hill, 2002.
- [۳۲] قنبر آذرینیا و محمدعلی طینتی، «افزایش همگرایی شبکه‌های تطبیقی با لینک‌های نویزی: الگوریتم حداقل میانگین مربعات

زیرنویس‌ها

- ¹ Fusion center
- ² Adaptive network
- ³ Incremental
- ⁴ Diffusion
- ⁵ Least mean square, (LMS)
- ⁶ Mean-square error, (MSE)
- ⁷ Maximum correntropy criteria
- ⁸ Steepest ascent
- ⁹ Iterative
- ¹⁰ Intermediate