

## یک فیلتر وفقی ترکیبی، از فیلترهای وفقی برای شناسایی سیستم

مرتضی فرهید

دانشگاه تبریز


morfid@gmail.com

چکیده- در این مقاله، برای شناسایی سیستم، ترکیب دو فیلتر عرضی وفقی LMS مطرح می شود. یکی از فیلترها دارای ضریب تطبیقی بالا و دیگری پایین است، به منظور اینکه امکان ترکیب tracking (تعقیب) بالا- تحت شرایط تغییرات سریع- همراه با کاهش خطای همگرایی را در تناوبهای ایستادن، بوجود آید. مثال شبیه سازی شده انتخابی تاثیر این روش را نشان خواهد داد.

کلمات کلیدی- فیلترهای وفقی، الگوریتم LMS، LMF، شناسایی سیستم

### ۱- مقدمه

جایی که خروجی فیلتر وفقی  $y$  با سیگنال مطلوب  $d$  مقایسه شده تا سیگنال خطای  $e$  را بوجود آورد که به فیلتر وفقی پس خور می شود. ضرایب فیلتر وفقی با بکار گیری الگوریتم های مختلفی از جمله LMS، بر پایه سیگنال خطا، تنظیم یا اپتیمایز می شوند.



شکل (۱): ساختار کلی فیلتر وفقی

خروجی فیلتر وفقی شکل ۱ به این صورت میباشد:

$$y(n) = \sum_{k=0}^{N-1} w_k(n) x(n-k)$$

اندازه گیری کارایی و بازده، بر پایه سیگنال خطا می باشد که تفاضل ما بین سیگنال مطلوب  $d(n)$  و خروجی فیلتر وفقی  $y(n)$  میباشد:

$$e(n) = d(n) - y(n)$$

ضرایب  $w_k(n)$  طوری تنظیم می شوند که امید<sup>۳</sup> تابع میانگین مربعات خطا، یعنی  $E[e^2(n)]$ ، مینی مایز گردد. چون  $k$  تا ضریب داریم، در نتیجه گرادینان تابع میانگین مربعات خطا، لازم است.

البته می توانیم بجای استفاده از گرادینان  $e^2(n)$ ، از رابطه زیر استفاده کنیم:

فیلترهای وفقی، برای مواقعی که سیگنال یا پارامترهای سیستم تغییرات کندی دارند، بهترین گزینه می باشند، یعنی این فیلتر تنظیم شده تا این تغییرات را جبران سازی کند.

الگوریتم LMS<sup>۱</sup> (widrow and hoff)، (حداقل میانگین مربعات) یک روش جستجویی برای تغییرات ضرایب فیلتر است. در فیلترهای دیجیتال FIR و IIR، فرض بر این است که پارامترهای پروسه برای مشخص کردن مشخصات فیلتر، شناخته شده است. آنها ممکن است با زمان تغییر کنند، اما طبیعت تغییر آنها بر فرض شناخته بودن قرار دارد. در بسیاری از مسایل عملی، ممکن است ابهام زیادی در بعضی پارامترها، بخاطر ناکافی بودن اطلاعات گذشته در مورد پروسه داشته باشیم. در بعضی از پارامترها، ممکن است انتظار تغییر پذیری با زمان را داشته باشیم ولی این تغییرات قابل پیش بینی نیستند.

در این موارد، مطلوب ماست که فیلتری طراحی کنیم بطوریکه self-learning باشد. در نتیجه می تواند خودش را با تغییرات وفق دهد. ضرایب فیلتر وفقی تنظیم شده تا برای تغییرات سیگنال ورودی، سیگنال خروجی یا پارامترهای سیستم جبران سازی انجام دهد.

بجای سفت و سخت بودن<sup>۲</sup>، سیستم وفقی می تواند مشخصات سیگنال را یاد بگیرد و تغییرات آرام آن را دنبال کند. فیلتر وفقی می تواند زمانی که درباره مشخصات سیگنال، اطلاعات قطعی نداریم یا هنگامی که این مشخصات تغییر می کنند، مفید واقع شوند. شکل ۱ ساختار پایه یک فیلتر وفقی را نشان می دهد

<sup>۱</sup> least mean square  
<sup>۲</sup> rigid

<sup>۳</sup> expectation

دربعضی از مثالها در شناسایی سیستم، کار <sup>7</sup>Harris، در صورت تغییر ADAPTION STEP بر حسب علامت خطای اخیر اجازه می دهد تا trad off بر طبق مکان و موقعیت اصلاح شوند.

بعضی از ترکیبات الگوریتم های متغیر با زمان LMS و LMF (least mean fourth) بوسیله چند قانون تجربی، تلاش می کنند تا مزایای مختلف هر دو نوع الگوریتم بکار گرفته شوند و زوج ترکیب LMS و حداقل میانگین مطلق<sup>8</sup> در حضور نویز ایمپالسی در شناسایی سیستم با هم به رقابت پردازند. در همه موارد بالایی بجز اولی، ترکیب طراحی های مختلف به صرفه، برای بدست آوردن مصالحه ای بین تغییرات سرعت با همگرایی است.

در [6] فقط ADAPTION STEP الگوریتم LMS به ترتیب متناسب با افزایش سرعت / کاهش خطا، افزایش / کاهش پیدا می کنند.

ما ملاحظه می کنیم که نظریه استفاده از ADAPTIVE STEP مناسب است. با این وجود، در واقع بوضوح بنظر می رسد که طراحی در ارتباط با همین قانون وفقی، یک سوال مطلوب است. درعمل، با بکارگیری علائم خطا، تاثیرات منفی نویز و همگرایی غیر مونوتونیک را با دیده اغماض بررسی می کنیم. به عبارت دیگرخوبی این واقعیت بر ما آشکار است که خطا در این طرح رجیسترهای نویزی زیادی دارد. در اینجا ما قوانین پایه بالایی را تحت روشهای مختلف بررسی می کنیم.

## ۲- طرح پیشنهادی

برای شناسایی سیستم، ترکیبی از دو فیلتر عرضی وفقی LMS را مطرح می کنیم. بوضوح این معادل است با آنکه در هر لحظه فقط یک فیلتر عرضی وجود دارد. یکی از فیلترهای وفقی  $w_1[k]$ ، سریع است: ثابت وفقی آن،  $\mu$  نسبتا بزرگ است. وسیله دوم  $w_2[k]$  کند است: با ADAPTION STEP نسبتا پایین  $\mu_2$  کار میکند. اما این دومی، ما را به مکانهای پایدار steady-state با خطای شناسایی پایین رهنمون می سازد.

در نتیجه اگر ما این معادله را بکار ببریم:

$$W_{eq}[k] = \lambda[k]w_1[k] + (1-\lambda[k])w_2[k] \quad (1)$$


$$w[k+1] = w[k] + \mu ex[k]$$

که بیانگر الگوریتم LMS است. [1]

الگوریتم LMS (widrow and hoff) [2]، یک روش سرراست و قطعی برای فیلترینگ عرضی<sup>5</sup> وفقی، برای شناسایی سیستم در خیلی از کتابها بکار برده شده است. [3,4,5]

شکل ۲ ساختار فیلتر وفقی که برای شناسایی سیستم یا مدل کردن<sup>6</sup>، بکار می رود را نشان می دهد. یک ورودی یکسان، برای سیستم ناشناخته، موازی با فیلتر وفقی اعمال می گردد. سیگنال خطا  $e$ ، تفاضل بین پاسخ سیستم ناشناخته  $d$  و پاسخ فیلتر وفقی  $y$  است. این سیگنال خطا به فیلتر وفقی پسخور می شود تا ضرایب فیلتر را، تا زمانی که کل خروجی  $y=d$  گردد، بهنگام کند. یک مصالحه خوب ما بین مرحله خطای ایستادن و توانایی تعقیب، احتمالا از مزایای عمده استفاده از LMS است. ADAPTION STEP برای این منظور بکار گرفته می شود تا یک توازن دقیق ما بین سرعت در برابر همگرایی را انتخاب نماید.

در نتیجه، اثبات می شود که LMS استاندارد، فقط یک پارامتر ADAPTION STEP را برای برقراری trade-off های بالایی لازم دارد. همچنین واضح است که یک پیچیدگی کمی می تواند قابل قبول باشد، به ازای افزایش درجه آزادی تا توازن سرعت در تقابل با همگرایی بهتر شود.



شکل (۲): ساختار کلی شناسایی سیستم

<sup>8</sup> Least Mean Absolute  
<sup>9</sup> plant

<sup>4</sup> least mean square  
<sup>5</sup> transversal  
<sup>6</sup> modeling

و  $\lambda[k]$  را بزرگ انتخاب کنیم (در صورت لزوم، نزدیک یک) برای tracking سریع مکانها، وپایین باشد (نزدیک صفر) برای بازه های ایستادن، در حقیقت ما ترکیب کرده ایم توانایی tracking بالا  $w_1[k]$  را با بازدهی بالای steady-state  $w_2[k]$ .

برای این کار، کفایت که  $\lambda$  را بر طبق الگوریتم LMS، با پارامتر وفق دهنده  $\mu_1$ ، که خیلی بزرگتر از  $\mu_2$  (و در نتیجه،  $\mu_2$ ) می باشد، وفق دهیم.

هیچ نشانه ای از مشکل واگرایی نخواهیم داشت:

$\lambda[k]$  در بازه  $[0,1]$  نگه داشته می شود، فقط برای بدست آوردن ترکیب دو گانه (بعبارت دیگر طرح می تواند از لحاظ کنترلی خاموش باشد).

روش وفق دادن  $\lambda$  از رابطه زیر بدست می آید:

(2)

$$\nabla_{\lambda} e^2 = \nabla_{\lambda} (y - w_{eq}^T x)^2 = -2(y - w_{eq}^T x)(w_1^T - w_2^T)x$$
 در نتیجه، و طبق شکل ۳ ما الگوریتم هارا به شرح زیر اعمال می کنیم: LMS استاندارد برای فیلترها

$$w_i[k+1] = w_i[k] + \mu_i(y[k] - w_i^T[k]x[k])x[k] \quad i=1,2 \quad (3a)$$

و بر طبق (2)، متشابهها برای پارامترهای ترکیبی

$$\lambda[k+1] = \lambda[k] + \mu_{\lambda}(y[k] - w_{eq}^T[k]x[k])(w_2^T[k] - w_1^T[k])x[k]\{\lambda[k](1-\lambda[k])+10^{-2}\}$$

$$0 < \lambda[k] < 1 \quad (3b) \quad \text{نگهداشتن}$$

توضیح اینکه، ما فاکتور  $(1-\lambda[k])10^{-2} + \lambda[k]$  را با گرادیان  $\lambda$  جمع می بندیم: فقط برای کاهش سرعت همگرایی برای  $\lambda$  نزدیک صفر یا یک، بدون اینکه الگوریتم نقطه توقفی داشته باشد. بحث کیفی بازدهی طرح، خیلی ساده است: توانایی تعقیب برای تغییرات ناگهانی با توجه به  $\mu_1$  ( $\lambda[k] \rightarrow 1$ ) را داراست و نیز خطای باقیمانده با توجه به  $\mu_2$  ( $\lambda[k] \rightarrow 0$ ) برای تناوبهای ایستادن.

در موقعیتهای میانی،  $\lambda[k]$  دارای مقادیر میانی (متوسط)، و همگرایی اش نیز مخلوطی (ترکیبی) از  $w_1[k]$  و  $w_2[k]$  خواهد بود. در نتیجه ما یک ترکیب منطقی با هر دو الگوریتم LMS را بدست می آوریم، با فرض آنکه خیلی نویز آلود نباشد. همچنین واضح است که شرایط همگرایی معمول، باید با  $\mu_1$  حاصل شود. با کمی توجه به این روش، ملاحظه می کنیم که طرح مورد نظر مزیتی از جمله، اجتناب از روش سویچینگ را داراست. بکار بردن یکی از فیلترها در هر لحظه راه حل مناسبی نیست، برای مواقعی که تغییرات خیلی شدید نمی باشد. (ناگهانی یا حداقل خیلی سریع یا صفر یا حداقل خیلی کند). در بعضی از ترکیبها، بیشتر طرحهای پیشنهادی قبلی از این نقطه ضعف رنج می بردند.

### ۳- یک آزمایش گویا

ما تعداد زیادی از آزمایشها را به مرحله اتمام رسانیده ایم، که حاکی از این است: بطور قابل اجرایی، طرح مطرح شده و توضیحات مربوطه را ارضا می کند. در بین این آزمایشها، ما مثال شبیه سازی شده ای را انتخاب و بحث می کنیم.

در مثال ما،  $x$  و  $n$  مستقل از هم، گاوسی، سفید، میانگین صفر و به ترتیب دارای واریانسهای  $10^{-2}$  و  $1$  هستند، تا موقعی که

$$w[k] = w_c + w_v[k] \quad (4)$$

که plant سه شیر<sup>۱۰</sup> می باشد، در جایی که

$$w_c = [-.4706, -.7737, -.0291]^T$$


$$1 < k < 21000 \quad \text{برای}$$

$$w_c = [.4706, .7737, .0291]^T$$

$$21000 < k < 28000$$

(مقادیر ضرایب انتخابی بطور تصادفی در بازه توزیع یکنواخت


$[0,1]$  حاصل شده است.) و  $w_v[k]$  نتیجه کاهش<sup>۱۱</sup> 436:1 بعلاوه



شکل (۳): طرح پیشنهادی با دو نوع ضریب تطبیقی

<sup>10</sup> tap

<sup>11</sup> decimating



شکل (۴): نتایج شبیه سازی

#### ۴-نتیجه گیری

یک ترکیب مستقیم دوگانه وقفی از یک فیلتر وقفی سریع و دیگری فیلتر وقفی کند برای بدست آوردن هر دو توانایی tracking اولی و درجه همگرایی بالای دومی برای شناسایی سیستم مورد استفاده قرار گرفت در صورتیکه وفق دهنده (adaption) ترکیبی به حد کافی سریع باشد.

کار طرح ترکیب شده براحتی قابل فهم و قابل طراحی است. مثالهای کاربردی، مفید بودن این روش و مزایایش را اثبات می کنند.

البته جا برای کار در این نظریه وجود دارد.

اول، تشریح خطاهای مرجع برای  $w_2$  و  $w_1$ . موارد دیگر، از بکار بردن step متغیر  $\mu_k$  بستگی به مقدار خود  $\lambda[k]$  بهبود بخشیدن دوباره به ظرفیت پایه طرح، با بکارگیری ماتریس قطری با عناصر مختلفی که وفق یافته اند، به منظور مبارزه با پراکندگی مقادیر ویژه، در روشی مشابه، اما با نگهداشتن مزایای مدل مان.

درون یابی<sup>۱۲</sup> بهینه رشته نویز مثلث بالایی ها (فوق الذکر)، ولی با واریانسهای:

$$\begin{aligned} 10^{-4} & 0 < k < 7000 \\ 10^{-2} & 7001 < k < 14000 \\ 0 & 14001 < k < 21000 \\ 10^{-2} & 21001 < k < 28000 \end{aligned}$$

این plant برای این انتخاب شده است که نشان دهد، بازدهی طرح ترکیبی برای تغییرات سریع و کند، به همان خوبی در طول تناوبهای ایستان است.

پارامترهای الگوریتم عبارتند از:  $\mu_1 = 0.05$ ،  $\mu_2 = 0.002$

شکل ۴ بطور متوسط ۱۰ آزمایش را نشان می دهد (a). متوسط مجذور فواصل ما بین plant مجهول و plant وقفی را برحسب dB نشان می دهد

$$MSD[k] = \|W[k] - W_1[k]\|_2^2$$

برای استفاده (کاربرد)  $W_1[k]$ ، و شکل 4(b), 4(c)، دارای دامنه های مشابهی هستند زمانی که به ترتیب  $w_2[k]$  اعمال می شود و  $w_{eq}[k]$  حاصل می گردد.

آنچنان که انتظار می رفت، فیلتر با step بالا،  $\mu_1 = 0.05$  توانایی تعقیب بهتری در شروع را داراست، در طی بازه تغییرات سریع  $7001 < k < 14000$  و زمانی که تغییرات ناگهانی از خود بروز می دهد ( $k = 21001$ ) با این وجود، آن قادر نیست در بازه نسبتاً آرام  $1 < k < 700$  به خطای زیر 30db دست پیدا کند.

بر خلاف آنچه بیان شد فیلتر با  $\mu_2 = 0.002$  adaption step کند تر است. زمانی که تغییرات ناگهانی رخ می دهد، اما تقریباً خطای پایین تری را به دنبال دارد: نه فقط برای بازه آرام  $1 < k < 700$ ، اما تقریباً برای تکه نهایی  $21001 < k < 28000$ ، اگر چه در طی بازه  $7001 < k < 14000$  نمی تواند تغییرات plant را دنبال کند. دیده شد که طرح ترکیبی، توانایی LMS tracking سریع با خطای پایین فیلتر برای تناوبهای ایستان را داراست. برای  $1400 < k < 21001$  همگرایی اولیه را ببینید و بعد برای  $k = 21001$  پرش را، بازده مربوطه به همان خوبی است در طول بازه  $7001 < k < 14000$  تا زمانی که  $w[k]$  قادر نیست plant را تعقیب کند).



نیازی به گفتن نیست، امکان اینکه می توانیم این مفاهیم را به نگرانی منطقی برای طراحی داشته باشیم . همه این توسعه و مسایل دیگر فیلترینگ وقفی اعمال کنیم . از digital پیشرفتهای در حال حاضر بوسیله نویسندگان در حال تکمیل و equalization گرفته تا آرایه های وقفی ، فقط باید یک آینده بررسی هستند .

2.N.kaloupsidis,S.Theodoris,Adaptive System  
Identification and Signal processing Algorithms,Hemel  
Hempstead,Heartfordshire,UK:prentice-hall,1993  
3.E.Walach,B.widrow,"the least mean  
fourth(LMF)algorithm "IEEE trans.information  
theory,vol IT -30,n 17,pp1423-1424,1995

مراجع

1.S.Haykin,Adaptive filter theory (4<sup>th</sup>)Upple saddle  
River ,NJ:prentice-hall,2002  
2.N.kaloupsidis,S.Theodoris,Adaptive System  
Identification and Signal processing Algorithms,Hemel  
Hempstead,Heartfordshire,UK:prentice-hall,1993