

## ارائه یک موتور پیش‌بینی مبتنی بر ترکیب اطلاعات جهت پیش‌بینی قیمت در بازارهای برق

علی درودی<sup>۱</sup>، کارشناس ارشد، مسعود بشری<sup>۱</sup>، دانشجوی دکتری، محمد حسین جاویدی دشت بیاض<sup>۱</sup>، استاد

۱- دانشکده مهندسی برق - دانشگاه فردوسی مشهد - مشهد - ایران

al.darudi@stu-mail.um.ac.ir

**چکیده:** در بازارهای برق تجدیدساختاریافته، پیش‌بینی صحیح قیمت اهمیت فراوانی برای تمامی شرکت‌کنندگان بازار دارد. به دلیل ویژگی‌های خاص و پیچیدگی‌های سیگنال قیمت بازار، یک موتور پیش‌بینی نمی‌تواند به تنهایی تمامی الگوهای مختلف موجود در سیگنال قیمت را شناسایی و مدل نمایند. بنابراین، جهت افزایش صحت پیش‌بینی‌ها، این مقاله یک روش هیبرید کننده ارائه می‌دهد تا بتواند از به صورت همزمان از مزیت‌های چند موتور پیش‌بین استفاده نماید. در روش پیشنهادی سه موتور پیش‌بین مقدماتی پیش‌بینی‌هایی مستقل از قیمت بازار برق ارائه می‌دهند. سه موتور پیش‌بینی مقدماتی استفاده شده در این مقاله عبارتند از: شبکه‌های عصبی مصنوعی چند لایه، سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) و روش میانگین متحرک خودگردان (ARMA). سپس یک الگوریتم ترکیب اطلاعات جدید ارائه شده است که این سه پیش‌بینی مستقل را با یکدیگر ترکیب نموده تا یک پیش‌بینی واحد از قیمت برق ارائه نماید. روش پیشنهادی از میزان خطای گذشته موتورهای پیش‌بین مقدماتی بازخورد گرفته تا میزان تاثیر آن‌ها را در پیش‌بینی نهایی تنظیم نماید. روش پیشنهادی بر روی داده‌های قیمت بازار اسپانیا اعمال شده اند تا کارایی آن ارزیابی شود. نتایج نشان می‌دهد که روش پیشنهادی می‌تواند پیش‌بینی‌هایی ارائه دهد که از هرکدام از پیش‌بینی‌های موتورهای مقدماتی بهتر است.

**واژه‌های کلیدی:** بازار برق، پیش‌بینی قیمت، ترکیب اطلاعات (فیوژن)، میانگین موزون ترتیبی، انتگرال فازی چکوئیت.

تاریخ ارسال مقاله : ۱۳۹۳/۷/۱۴

تاریخ پذیرش مقاله : ۱۳۹۳/۱۲/۱۶

نام نویسنده‌ی مسئول : محمد حسین جاویدی دشت بیاض

نشانی نویسنده‌ی مسئول : مشهد - میدان آزادی - دانشگاه فردوسی مشهد - دانشکده مهندسی - لابراتوار تجدید ساختار

## ۱- مقدمه

شرکت کنندگان در بازارهای برق کنونی علاقه‌مندند تا نسبت به آینده وضعیت بازار برق آگاهی یابند تا بتوانند رفتار خود را متناسب با آن تنظیم نمایند. به طور خاص، پیش‌بینی قیمت بازار برق، که از مهم‌ترین سیگنال‌های بازار است [۱]، نقش بسیار مهمی برای بازیگران بازار دارد. پیش‌بینی صحیح قیمت بازار برق برای تمامی شرکت کنندگان مفید است؛ شرکت‌های تولید توان و مصرف کنندگان بزرگ به کمک پیش‌بینی قیمت بازار می‌توانند استراتژی پیشنهاد قیمت مناسب اختیار کنند و خود را در مقابل نوسانات قیمت مقاوم نمایند و بهره‌وری اقتصادی خود را افزایش دهند [۲]. شرکت‌های انتقال می‌توانند بر اساس پیش‌بینی قیمت، برنامه‌ریزی‌های کوتاه مدت خود را در مورد خروج واحدها و برنامه‌های پاسخگویی بار تنظیم نمایند و شرکت‌های بهره‌بردار بازار نیز می‌توانند از پیش‌بینی قیمت توان برای برنامه‌ریزی و بهره‌برداری شبکه استفاده نمایند [۳].

پیش‌بینی سری زمانی قیمت بازارهای برق، به خاطر ویژگی‌های خاص آن، کار دشواری است؛ ویژگی‌هایی مانند:

- واریانس و میانگین متغیر
  - نوسانات زیاد
  - نوسانات دوره ای متعدد فصلی/ هفتگی [۳]
  - وابستگی قیمت به فاکتورهای متعدد مانند قیمت سوخت، تولید آبی و رفتار شرکت‌های تولیدی [۱]
- پیش‌بینی‌های ارائه شده کنونی خطایی در محدوده ۴٪ تا ۳۵٪ دارند که هنوز از دیدگاه مدیریت ریسک چندان قابل قبول نیستند [۴].

تا کنون، روش‌های بسیار متعددی برای پیش‌بینی سیگنال‌های مختلف بازار برق پیشنهاد شده‌اند. به عنوان مثال، جهت پیش‌بینی قیمت بازار برق، روش‌های سری زمانی مانند میانگین متحرک خودگردان یکپارچه\* [۵]، گارچ† [۶] و روش ویولت-آریماف‡ [۷] ارائه و پیاده شدند. به مرور زمان، روش‌های پیشرفته‌تری مانند تکنیک نزدیک‌ترین همسایه‌های موزون§ [۸]، روش‌های مبتنی بر شبکه‌های عصبی [۹] و شبکه‌های فازی عصبی [۱۰] نیز جهت پیش‌بینی قیمت بازار برق ارائه شدند. با این وجود، تمامی این روش‌های پیشنهادی بر مبنای تنها یک موتور پیش‌بین عمل می‌نمایند که تنها قسمت محدودی از ویژگی‌های رفتاری سیگنال هدف را می‌توانند شناسایی کنند. بنابراین، جای هیچ شگفتی نمی‌باشد که هیچکدام از این روش‌ها نمی‌توانند در تمامی شرایط بازار از بقیه بهتر عمل نمایند [۱۱].

اخیراً، روش‌های پیش‌بینی هیبرید مورد توجه محققان قرار گرفته است. این روش‌ها سعی می‌کنند که از نکات قوت چند موتور پیش‌بین به صورت همزمان استفاده نمایند. مدل‌های هیبرید متعددی توسط محققان ارائه شد است که چندین موتور پیش‌بین معمولی را با یکدیگر ترکیب می‌کنند. اثر بخشی روش‌های هیبرید به وسیله کوشش‌های تئوری و نتایج عملی تایید شده است [۱۲]. ما روش‌های هیبرید کنونی را به دو دسته تقسیم می‌نماییم:

- چند مرحله‌ای
  - مبتنی بر پیش‌بینی خطا
- در روش‌های چند مرحله‌ای، چند موتور پیش‌بین مختلف به صورت آبشاری پشت سر هم قرار می‌گیرند؛ بدین معنا که خروجی یک موتور پیش‌بین به عنوان ورودی به موتور بعدی داده می‌شود [۱]. [۱۳]-[۱۵]. از سوی دیگر، در روش‌های مبتنی بر پیش‌بینی خطا، از یک موتور پیش‌بین کمکی استفاده می‌شود تا خطای پیش‌بینی موتور پیش‌بین اصلی را تخمین بزند و بر آن اساس خروجی نهایی اصلاح می‌شود [۱۱]، [۱۶].

موتور پیش‌بین پیشنهادی ما رویکردی جدید جهت هیبرید کردن موتورهای پیش‌بینی ارائه می‌دهد. در روش پیشنهادی، مشابه سایر روش‌های هیبرید، از سه موتور پیش‌بین مستقل استفاده شده است که عبارتند از شبکه‌های عصبی مصنوعی (ANN) و سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) و روش میانگین متحرک خودگردان (ARMA). با این وجود، بر خلاف سایر روش‌های هیبرید رایج، هر کدام از موتورهای پیش‌بین مستقیماً متغیر هدف (قیمت بازار) را پیش‌بینی می‌کنند. سپس، الگوریتم ترکیب اطلاعات (فیوژن) این پیش‌بینی‌های مستقل را با یکدیگر ترکیب می‌کند تا یک پیش‌بینی واحد ارائه شود. انتظار داریم که پیش‌بینی‌های ترکیب شده بهتر از پیش‌بینی‌های مقدماتی باشند.

در این مقاله، ما یک راهبرد جدید برای هیبرید کردن چند موتور پیش‌بین مختلف ارائه می‌دهیم که مبتنی بر ترکیب اطلاعات است. ترکیب اطلاعات (فیوژن) به راهبردها و روش‌هایی اطلاق می‌شود که داده‌های جمع شده از منابع مختلف را با یکدیگر ترکیب می‌کند. هدف از اجرای ترکیب اطلاعات، به دست آوردن اطلاعاتی با کیفیت بالاتر است. منظور از کیفیت بالاتر با توجه به نوع کاربرد تعریف می‌گردد [۱۷]. بدین ترتیب، در کاربرد پیش‌بینی، منظور از داده‌های ورودی، پیش‌بینی‌های اولیه از متغیر هدف، و منظور از کیفیت بالاتر، پیش‌بینی‌هایی با صحت بالاتر است.

تاکنون، از ترکیب اطلاعات در زمینه‌های متعددی استفاده شده است؛ مانند اندازه‌گیری، رباتیک و کاربردهای مخابراتی. یکی از مهم‌ترین کاربردهای ترکیب اطلاعات در ترکیب سنسوری است [۱۸]. چنانچه چند سنسور مختلف جهت اندازه‌گیری یک متغیر خاص اختصاص دهیم، مقادیر اندازه‌گیری شده توسط این سنسورها با

\* auto-regressive integrated moving average (ARIMA)  
 †generalized auto-regressive conditional heteroskedastic (GARCH)  
 ‡ Wavelet-ARIMA  
 § weighted nearest neighbors techniques

یکدیگر متفاوت است. می‌توان این مقادیر اندازه‌گیری شده را توسط روش‌های مبتنی بر ترکیب اطلاعات با یکدیگر ادغام نمود تا یک مقدار واحد برای متغیر هدف به دست آید. به عنوان مثال، در مرجع [۱۹] از ترکیب داده‌ها برای محاسبه نرخ جریان یک مایع به کمک چند سنسور غیر متمرکز استفاده شده است. نتایج نشان می‌دهد که روش ترکیب اطلاعات توانسته است صحت تخمین نرخ جریان را افزایش دهد. از ترکیب اطلاعات، برای تخمین موقعیت ربات‌ها نیز استفاده شده است [۲۰]. در این مرجع، فیلتر ترکیب کالمن، دو تخمین صورت گرفته توسط یک مسافت سنج و یک دوربین را با یکدیگر ترکیب می‌کند. نتایج نشان می‌دهد، تخمین روش ترکیب اطلاعات از تخمین‌های مسافت سنج و دوربین دقیق‌تر است. همچنین، در مرجع [۲۱]، داده‌های قدرت سیگنال و زمان تحویل با یکدیگر ترکیب شده‌اند تا مکان یک تلفن همراه تخمین زده شود. علیرغم استفاده موفقیت آمیز از روش‌های مبتنی بر ترکیب اطلاعات در زمینه‌های مختلف، از ترکیب اطلاعات برای پیش‌بینی، علی‌الخصوص پیش‌بینی در بازارهای برق، به ندرت استفاده شده است.

هدف از این پژوهش ارائه یک روش پیش‌بینی جدید برای پیش‌بینی کوتاه سیگنال قیمت در بازار برق است. موتور ارائه شده، دارای نوآوری‌های زیر نسبت به سایر پژوهش‌های مشابه است:

- یک چارچوب جدید مبتنی بر ترکیب اطلاعات ارائه شده است که پیش‌بینی‌های حاصل از سه موتور پیش‌بینی مقدماتی مستقل را با یکدیگر ترکیب می‌کند تا یک پیش‌بینی واحد به دست آید.
- یک الگوریتم ترکیب اطلاعات جدید ارائه شده است که از میزان خطای موتورهای پیش‌بین مقدماتی بازخورد می‌گیرد. بدین ترتیب، این الگوریتم، هنگامی که میزان صحت موتورهای پیش‌بین به میزان قابل توجهی از یکدیگر متفاوت است می‌تواند نتایج بهتری نسبت به سایر روش‌های ترکیب اطلاعات ارائه دهد.

ساختار مقاله به شرح زیر است. در بخش ۲، چارچوب پیشنهادی موتور پیش‌بینی ارائه می‌گردد. در بخش ۳، روش ترکیب اطلاعات پیشنهادی و دو روش ترکیب اطلاعات متداول ارائه خواهد شد. به منظور ارزیابی عملکرد روش پیشنهادی، در بخش ۴، از موتور پیش‌بین پیشنهادی برای پیش‌بینی ۲۴ ساعت بعد قیمت بازار برق اسپانیا استفاده شده است. نهایتاً، بخش ۵ به نتیجه‌گیری از نتایج روش پیشنهادی اختصاص یافته است.

هدف: عموماً، یک موتور پیش‌بین به تنهایی نمی‌تواند تمامی الگوهای تغییر را در یک متغیر شناسایی کند. بنابراین، استفاده از چندین موتور پیش‌بین متفاوت در روش ترکیب اطلاعات، به صورت بالقوه، می‌تواند منجر به تشخیص الگوهای متفاوت موجود گردد.

فرایند پیش‌بینی ساده‌تر: همین‌طور که قبلاً اشاره شد، الگوریتم‌های ترکیب اطلاعات می‌توانند صحت پیش‌بینی‌های نهایی را افزایش دهند. بنابراین، از موتورهای پیش‌بین مقدماتی ساده‌تری می‌توان استفاده نمود. بدین ترتیب، مشکل طراحی و آموزش موتورهای پیش‌بینی صحیح‌تر، که عموماً پیچیده‌تر نیز هستند، تخفیف پیدا می‌کند. بنابراین، با توجه به آنکه الگوریتم‌های ترکیب اطلاعات روش‌های نسبتاً ساده‌ای هستند، کل فرایند پیش‌بینی، با صحت پیش‌بینی قابل قبول، ساده‌تر خواهد شد.

### ۳- روش‌های ترکیب اطلاعات

پس از آنکه پیش‌بینی‌های مقدماتی فراهم آمدند، لازم است، الگوریتم‌های ترکیب اطلاعات مناسب اعمال شوند تا یک پیش‌بینی واحد فراهم آید. در این بخش ابتدا دو الگوریتم ترکیب اطلاعات معمولی شامل OWA و انتگرال فازی چکوئیت شرح داده می‌شوند. سپس، به منظور بهبود عملکرد روش‌های ترکیب اطلاعات، یک نسخه اصلاح شده از OWA نیز ارائه می‌گردد.

### ۲- چهارچوب پیشنهادی مبتنی بر ترکیب اطلاعات

چارچوب پیشنهادی ارائه شده این مقاله در شکل (۱) نشان داده شده است. الگوریتم ترکیب اطلاعات به تعدادی پیش‌بینی مقدماتی به عنوان ورودی خود نیاز دارد. بنابراین، ما ابتدا باید تعدادی موتور پیش‌بین مقدماتی انتخاب کنیم. در این پژوهش سه موتور ANN،

### ۳-۱- میانگین موزون ترتیبی\*\* (OWA)

روش میانگین موزون ترتیبی (OWA) یک الگوریتم ترکیب اطلاعات ساده اما محبوب است که توسط پیگردر [22] ارائه شده است. تا کنون، از OWA در کاربردهای گوناگون همانند تصمیم گیری، دسته بندی، داده کاوی و... به کار گرفته شده است (به منظور آشنایی کامل با کاربردها و مدل‌های نوین OWA می توان به [23] مراجعه کرد). خروجی OWA، ترکیبی خطی از ورودی‌های آن است:

$$OWA(t) = \sum_{k=1}^N w_k(t).agent_k(t) \quad \forall t \quad (1)$$

که در آن،  $w$  وزنه‌های نهایی هستند.  $N$  تعداد ورودی‌ها (تعداد موتورهای پیش بین مقدماتی) و  $agent_i(t)$  نیز آمین پیش بینی ورودی از لحاظ میزان بزرگی ( $agent_1(t) > agent_2(t) > \dots > agent_N(t)$ ) است. بنابراین، وزن‌های OWA به یک موتور پیش بین مقدماتی خاص اختصاص نیافته‌اند، بلکه به جایگاه ترتیبی آن‌ها از لحاظ میزان بزرگی مرتبط هستند. وزن‌ها دارای قیود زیر هستند:

$$\sum_{k=1}^N w_k(t) = 1 \text{ و } w_k \in [0, 1] \quad (2)$$

یکی از بزرگ‌ترین چالش‌های استفاده از OWA، چگونگی انتخاب وزن‌های آن است. می توان از روش‌هایی با وزن ثابت در طول زمان استفاده نمود که، احتمالاً، منجر به کاهش دقت خروجی می گردد. در عوض، در این پایان نامه، از روش کاهش گرادیان برای انتخاب وزن‌های ورودی OWA استفاده شده است که وزن‌های OWA را در هر گام پیش بینی به روز می نماید. ابتدا، جهت آنکه قیود (۲) برای  $w$ ها ارضا شوند، از یک تغییر متغیر به حالت زیر استفاده می نماییم:

$$w_i(1) = \frac{e^{\lambda_i(1)}}{\sum_{j=1}^N e^{\lambda_j(1)}} \quad (3)$$

که در آن،  $\lambda_i$  وزن‌های مقدماتی هستند. بر اساس رابطه فوق، به ازای تمام مقادیر ممکن برای وزنه‌های  $\lambda_i$ ، مقادیر وزنه‌های نهایی  $w$  قیود رابطه (۲) را ارضا خواهند کرد. حال لازم است فرمول کاهش گرادیان برای محاسبه وزن‌های مقدماتی  $\lambda_i$  را ارائه دهیم [24]:

$$\lambda_i(t+1) = \lambda_i(t) - \beta w_i(agent_i(t) - OWA(t)) (OWA(t) - d(t)), \forall i = 1, 2, \dots, N \quad (4)$$

که در آن،  $t$  گام زمانی و  $\beta$  یک پارامتر ساختاری است که نرخ یادگیری را تنظیم می نماید. نهایتاً، میزان خروجی مطلوب ترکیب اطلاعات،  $d(t)$ ، نیز توسط روش هورویکز (Hurwicz) محاسبه می شود:

$$d(t) = \rho \text{Max}_i(agent_i(t)) + (1 - \rho) \text{Min}_i(agent_i(t)) \quad 0 \leq \rho \leq 1 \quad (5)$$

که در آن،  $\rho$  میزان خوش بینی مطلوب ما را نشان می دهد. چنانچه بخواهیم پیش بینی‌هایی دست بالا برای متغیر هدف داشته باشیم، باید مقدار بالایی برای  $\rho$  انتخاب کنیم. در طرف مقابل، در یک پیش بینی محافظه کارانه‌ی دست پایین، باید مقدار  $\rho$  را نزدیک به صفر انتخاب نماییم.

فرمولاسیون فوق نشان می دهد که وزن‌ها، به تناسب تفاوتشان از پیش بینی ترکیب شده، اصلاح می شوند. نرخ این اصلاح نیز متناسب با میزان تفاوت مقدار پیش بینی ترکیب شده و میزان مطلوب ترکیبی  $(OWA(t) - d(t))$  است.

### ۳-۲- انتگرال فازی چکوئیت

در روش OWA، پیش بینی موتورهای پیش بین مقدماتی به صورت جداگانه از یکدیگر و با تخصیص یک وزن به هر کدام از آن‌ها در نظر گرفته شده‌اند. بنابراین، اطلاعاتی که به صورت بالقوه در رابطه بین این پیش بینی‌ها وجود دارد، در نظر گرفته نمی شوند. در این بخش، از یک روش ترکیب اطلاعات استفاده شده است که توانایی در نظر گرفتن اطلاعات موجود در ترکیب‌های مختلف پیش بینی‌های ورودی را داراست. ابتدا، از تئوری اندازه فازی (Fuzzy measure) استفاده می شود تا یک شاخص اهمیت (اندازه فازی) به هر کدام از زیر مجموعه‌های ترکیب‌های مختلف ورودی (یا همان پیش بینی‌های مقدماتی) اختصاص داده شود. سپس، جهت به دست آوردن پیش بینی واحد نهایی، لازم است از یک انتگرال فازی استفاده شود تا تمامی مقادیر اختصاص داده شده به ترکیب‌های مختلف را با توجه به اندازه فازی متناظرشان به یک مقدار نهایی تبدیل نماید.

### ۳-۲-۱- اندازه فازی

یک اندازه فازی نرمالیزه بر روی یک مجموعه متناهی  $(X = \{x_1, \dots, x_N\})$  یک تابع مجموعه‌ای (set function)  $(\mu)$  است که دارای شرایط زیر باشد:

$$\begin{aligned} \mu : P(X) &\rightarrow [0, 1], \\ \mu(\emptyset) &= 0, \mu(X) = 1, \\ A \subseteq B &\rightarrow \mu(A) \leq \mu(B) \end{aligned} \quad (6)$$

\*\* Ordered Weighted Average

بنابراین، تنها لازم است مقداری برای اندازه فازی برای هر ورودی  $(\mu(x_i), i = 1, \dots, N)$  انتخاب نماییم. متعاقبا، به کمک رابطه فوق می‌توان مقدار  $\lambda$  را محاسبه کرد. می‌توان اندازه فازی تمامی زیر مجموعه های  $X$  را با داشتن مقدار  $\lambda$  و استفاده از رابطه (7) محاسبه نمود.

در این مقاله، ما مقدار  $\mu(x_i)$  را برای هر ورودی را به صورت دستی انتخاب نموده‌ایم. به عبارت دیگر، به هر کدام از ورودی ها یک مقدار اهمیت مشابه اختصاص داده‌ایم، بدین معنا که همه آن ها دارای اهمیت مشابهی با یکدیگر هستند. رویکرد مناسب جایگزین دیگر می‌تواند آن باشد که مقدار  $\mu(x_i)$  ها را متناسب با مقدار خطای هر موتور پیش‌بین در گذشته انتخاب نماییم. بدین ترتیب که نشان می‌دهیم موتوری که دارای صحت بیشتری است، اهمیت بیشتری دارد و متعاقبا  $\mu(x_i)$  بالاتری دارد.

### ۳-۲-۲- انتگرال فازی چکوئیت

حال با تعدادی زیر مجموعه و اندازه فازی متناظرشان رو برو هستیم؛ درحالی‌که، ما یک مقدار واحد را به عنوان خروجی پیش‌بینی‌مان نیاز داریم. بنابراین، باید به دنبال یک روش موثر برای خلاصه‌سازی تمامی مقادیر تابع فازی به یک خروجی باشیم که بتواند اندازه‌های فازی متناظرشان را نیز در نظر بگیرد. انتگرال‌های فازی ابزارهای مناسبی برای این هدف هستند [26]. در این پژوهش، از انتگرال فازی چکوئیت استفاده شده است که توسعه‌ای بر انتگرال‌های معمولی است.

در این بخش لازم است که انتگرال فازی چکوئیت را تعریف کنیم. فرض کنید  $\mu$  یک اندازه فازی بر روی  $X$  است و  $f$  یک تابع بر روی  $X$  است که دارای برد  $\{a_1, \dots, a_n\}$  است که در آن  $a_1 < a_2 < \dots < a_n$ . انتگرال چکوئیت گسسته (C) بر روی  $f$  به صورت زیر تعریف می‌شود [26]:

$$C_\mu = \sum_{i=1}^N (a_i - a_{i-1}) \cdot \mu(\{x | f(x) \geq a_i\}) \quad (10)$$

که در آن  $a_0 = 0$

در کاربرد ما، اعضای  $X$  سه موتور پیش‌بین ANFIS، ANN و ARMA هستند. تابع  $f$  نیز نشان دهنده پیش‌بینی‌های این موتورها است. به عنوان مثال،  $f(x_1)$  نشان دهنده کمترین مقدار پیش‌بینی شده توسط موتورهای پیش‌بین است. به منظور پیش‌بینی متغیر هدف، باید پیش‌بینی‌های مقدماتی را به انتگرال چکوئیت داده شود تا مقدار نهایی پیش‌بینی به دست آید.

### ۳-۳- روش پیشنهادی OWA اصلاح شده

از روش‌های ترکیب اطلاعات انتظار می‌رود که بتوانند پیش‌بینی‌هایی بهتر از پیش‌بینی‌های مقدماتی ورودی ارائه نمایند. با این وجود، مشاهدات عملی ما نشان می‌دهد که اگر میزان صحت پیش‌بینی‌های

که در آن  $P(X)$  یک مجموعه توانی (power set) مجموعه  $X$  (تمامی زیر مجموعه های  $X$ ) است.  $X$  پیش‌بینی‌های موتورهای پیش‌بین مقدماتی هستند. در کاربرد ما که ۳ ورودی (موتور پیش‌بین مقدماتی) داریم  $P(X)$  دارای ۸ عضو است ( $2^3=8$ ). اندازه‌های فازی به معنی میزان اهمیت هر زیر مجموعه تفسیر شده‌اند [25]. برای  $A \subseteq X$ ،  $\mu(A)$  را می‌توان به صورت میزان توانایی و قدرت ترکیب  $A$  برای پیش‌بینی متغیر هدف بر اساس داده موجود در  $A$  تفسیر نمود (یعنی بدون در نظر گرفتن مقدار پیش‌بینی شده توسط اعضای خارج از مجموعه  $A$ ). بنابراین، با استفاده از اندازه فازی می‌توانیم قدرت هر کدام از ترکیب‌های مختلف ورودی‌ها را نیز برای پیش‌بینی متغیر هدف در نظر بگیریم (درحالی‌که در روش OWA تنها هر ورودی به صورت جداگانه لحاظ می‌شد).

حال، به موضوع چگونگی تخصیص میزان اندازه فازی به هر کدام از زیر مجموعه‌ها می‌پردازیم. باید یک روش ساختار یافته برای تخصیص یک اندازه فازی به هر یک از زیر مجموعه‌ها تبیین نمود. در این پژوهش، از روش اندازه فازی  $\lambda$  استفاده شده است [25] که دارای سادگی مناسبی است. در این روش، ابتدا، یک مقدار عددی اندازه فازی به هر یک از ورودی‌ها (پیش‌بینی‌های مقدماتی) اختصاص می‌یابد. سپس، پارامتر  $\lambda$  را می‌توان محاسبه نمود که کمک می‌کند اندازه فازی هر کدام از زیرمجموعه‌های ترکیب ورودی‌ها را تخمین بزنیم.

یک تابع مجموعه‌ای نرمالیزه را در اینصورت اندازه فازی  $\lambda$  می‌نامیم که برای هر جفت مجزا (disjoint) زیر مجموعه‌های  $A$  و  $B$  از  $X$  ( $A \cap B = \emptyset$  و  $A, B \subset X$ ) دارای شرایط زیر باشد:

$$\mu(A \cup B) = \mu(A) + \mu(B) + \lambda \mu(A) \mu(B),$$

for some  $\lambda > -1$

(7)

بنابراین، می‌توان روابط زیر را می‌توان استنتاج نمود:

$$\begin{aligned} \mu(\{x_1, \dots, x_l\}) &= \sum_{i=1}^l \mu(x_i) + \\ &\lambda \sum_{i=1}^{l-1} \sum_{j=i+1}^l \mu(x_i) \mu(x_j) + \dots \\ &+ \lambda^{l-1} \mu(x_1) \mu(x_2) \dots \mu(x_l) = \\ &\frac{1}{\lambda} \left[ \prod_{i=1}^l (1 + \lambda \mu(x_i)) - 1 \right] \end{aligned}$$

(8)

به کمک استفاده از رابطه بالا و شرط نرمالیزه بودن اندازه فازی  $\lambda$  ( $g(X)=1$ )، می‌توان نوشت:

$$1 + \lambda = \prod_{i=1}^N (1 + \lambda \mu(x_i)) \quad (9)$$

$$w_k'(t) = w_k(t), k = 1, \dots, N \quad (12)$$

به طوری که، مقدار  $w_k(t)$  به وسیله OWA اصلی محاسبه شده است (روابط (۳) تا (۵) OWA اصلی). اما در صورتی که عامل نامطلوبی (u) پیدا شده باشد، ضریب وزنی متناظر با آن را صفر می‌کنیم:

$$w_u'(t) = 0 \quad (13)$$

بدین ترتیب، اثر عامل نامطلوب در خروجی خنثی می‌شود. حال با توجه به آنکه باید شرط  $\sum_{k=1}^N w_k'(t) = 1$  نیز برقرار باشد، لازم است وزن‌های سایر ورودی‌ها نیز اصلاح گردند. ما ضریب حذف شده از عامل نامطلوب را به بهترین ورودی موجود (که با b نشان می‌دهیم) اختصاص می‌دهیم:

$$w_b'(t) = w_b(t) + w_u(t) \quad \forall t \quad (14)$$

#### ۴- نتایج عددی

به منظور ارزیابی روش پیش‌بینی پیشنهادی مبتنی بر ترکیب اطلاعات، از آن برای پیش‌بینی ۲۴ ساعت بعد قیمت بازار برق اسپانیا در ۴ هفته مختلف سال استفاده کردیم. خاطر نشان می‌شود که بازار اسپانیا یک بازار با انحصار دو جانبه با یک بازیگر غالب است. بنابراین، شاهد نوساناتی در قیمت برق هستیم که حاصل رفتار استراتژیک بازیگر غالب است. در نتیجه، پیش‌بینی قیمت در بازار اسپانیا کار دشواری است.

در این قسمت، معیار سنجش خطا و چگونگی تقسیم داده‌ها به گروه‌های آزمون، اعتبارسنجی و تست بیان می‌شود. عملکرد روش‌های پیش‌بینی بر اساس واحد خطای هفتگی در واحد ارزیابی خواهد شد:

$$e_{week} = \frac{1}{168} \sum_{t=1}^{168} \frac{|P_t^{true} - P_t^f|}{\bar{P}_{week}^{true}} \quad (15)$$

که در آن:

$$\bar{P}_{week}^{true} = \frac{1}{168} \sum_{t=1}^{168} P_t^{true} \quad (16)$$

که در آن،  $P_t^f$  و  $P_t^{true}$  به ترتیب نشان دهنده مقدار واقعی و پیش‌بینی شده قیمت است.

واریانس خطای هفتگی ( $\sigma_{week}^2$ ) نیز به عنوان معیاری از عدم قطعیت پیش‌بینی‌ها مورد بررسی قرار خواهند گرفت:

$$\sigma_{week}^2 = \frac{1}{168} \sum_{t=1}^{168} \left( \frac{|P_t^{true} - P_t^f|}{\bar{P}_{week}^{true}} - e_{week} \right)^2 \quad (17)$$

هرچقدر که میزان واریانس خطا کمتر باشد، پیش‌بینی قیمت دقیق‌تر و مطمئن‌تر خواهد بود.

مقدماتی به شدت با یکدیگر متفاوت باشد، عملکرد روش‌های ترکیب اطلاعات به شدت افت می‌کند. به عبارت دیگر، چنانچه یک موتور پیش‌بین مقدماتی خطایی بسیار بالاتر از سایر موتورها داشته باشد، الگوریتم ترکیب اطلاعات دچار گمراهی خواهد تا حدی که ممکن است پیش‌بینی‌هایی با خطایی بیشتر از خود موتورهای مقدماتی ارائه دهد.

در این بخش، نسخه‌ای اصلاح شده از الگوریتم OWA ارائه می‌دهیم که می‌تواند شرایطی را که میزان خطای موتورهای مقدماتی به شدت از یکدیگر متفاوت است، مدیریت نماید. مفاهیم اصلی روش پیشنهادی مشابه روش OWA است. با این وجود، در روش پیشنهادی ما، اگر یک ورودی به شدت بدتر از دیگران عمل نماید، اثر (احتمالاً) منفی آن بر خروجی ترکیب اطلاعات به طور کلی خنثی می‌شود. این امر، با صفر کردن ضریب وزنی متناظرش در خروجی ترکیب اطلاعات انجام می‌پذیرد.

جهت پیاده سازی اصلاحات مد نظر، ابتدا باید یک مقیاس سنجش عملکرد برای موتورهای پیش‌بین مقدماتی تعریف گردد. نمی‌توان از خطای کنونی موتورهای پیش‌بینی به عنوان مقیاس عملکرد آن‌ها استفاده نمود؛ زیرا، در هر گام زمانی، خطای کنونی هر موتور پیش‌بین مقدماتی مشخص نیست. به عنوان مثال، در پیش‌بینی‌های ۲۴ ساعت بعد، تنها خطای مربوط به بیش از ۲۴ ساعت پیش از زمان حال قابل اندازه‌گیری است. در واقع، به همین دلیل بود که OWA اصلی نمی‌توانست از خطای پیش‌بینی موتورهای پیش‌بین مقدماتی بازخورد دریافت کند. بنابراین، پیشنهاد می‌کنیم که از میزان خطای موتورهای پیش‌بین در روز گذشته به عنوان مقیاس سنجش عملکرد استفاده نمود. در واقع، ما فرض نموده‌ایم که عملکرد موتورهای پیش‌بین مقدماتی در کوتاه مدت (فاصله زمانی دو روز پیش) تغییر چندانی نمی‌کند. بدین ترتیب، چنانچه خطای روز پیشین یک موتور پیش‌بین به شدت از سایر موتورها بدتر باشد، فرض می‌شود که در حالا حاضر نیز خطای بالایی خواهد داشت و آن موتور پیش‌بین مقدماتی به عنوان عامل نامطلوب شناخته می‌شود. اثر این عامل نامطلوب در خروجی باید خنثی شود. بدین ترتیب، احتمالاً سایر موتورهای مقدماتی باقیمانده دارای عملکرد مشابهی با یکدیگر خواهند بود که منجر به افزایش صحت پیش‌بینی نهایی خواهد شد.

طرز عملکرد روش OWA اصلاح شده در زیر آمده است. روابط (1) تا (5) OWA اصلی نیز در به کار می‌روند. یک عامل نامطلوب را به این صورت تعریف می‌کنیم: چنانچه خطای مطلق پیش‌بینی یکی از ورودی‌ها در روز پیشین بیش از سه برابر بدتر از سایر ورودی‌ها در زمان مشابه باشد، آن ورودی را یک عامل نامطلوب می‌نامیم، که با u نشان می‌دهیم. در صورت عدم وجود عامل نامطلوب داریم:

$$MOWA(t) = \sum_{k=1}^N w_k'(t) \cdot agnt_k(t) \quad \forall t \quad (11)$$

که در آن:

پارامترهای ساختاری الگوریتم های ترکیب اطلاعات به شرح زیر تنظیم شده اند: در OWA و OWA اصلاح شده اندازه گام یادگیری  $\beta = 1$  و ضریب خوش بینی  $\rho = 0.5$  انتخاب شده اند. این مقدار ضریب خوش بینی نشان می دهد که ما به دنبال یک پیش بینی متعادل هستیم. همچنین، در روش انتگرال فازی چکوئیت فرض نموده ایم که تمامی ورودی ها دارای اهمیت مشابهی برای ما هستند. بنابراین به هر کدام از آن ها اندازه فازی مشابه  $\mu(x_i) = 0.4$  اختصاص داده ایم.

شکل (۲) نشان می دهد چگونه داده ها چگونه برای آموزش موتورهای پیش بین مقدماتی و مبتنی بر ترکیب اطلاعات استفاده می شود. ابتدا، در دوره آموزش ورودی های انتخاب شده و تعداد متعددی موتور مقدماتی آموزش می بینند. سپس، در مرحله اعتبار سنجی، ساختاری که کمتری خطا را نشان دهد، انتخاب می شوند تا برای پیش بینی در دوره تست استفاده شوند. همچنین، در مرحله پیش تست، پیش بینی های موتورهای پیش بین مقدماتی انتخاب شده به دو الگوریتم OWA و OWA اصلاح شده داده می شود تا اثر شرایط اولیه بر روی وزن های این دو الگوریتم کاهش یابد.

جدول (۱): خطای هفتگی در واحد برای هفته های مختلف سال ۲۰۰۲ اسپانیا - مقایسه عملکرد موتورهای مقدماتی با روش های ترکیب اطلاعات

روش های ترکیب اطلاعات (فیوژن)				موتورهای مقدماتی			هفته های تست
درصد بهبود OWA اصلاح شده	OWA اصلاح شده پیشنهادی	انتگرال فازی چکوئیت	OWA	ANFIS	ANN	ARMA	
۹۰.۶	۵.۵۲	۵.۵۴	۵.۵۲	۶.۶۴	۶.۰۲	۶.۷۱	اول (۱۸ تا ۲۴ فوریه)
۱۲.۱۳	۵.۰۳	۵.۱۸	۵.۰۳	۶.۴۱	۵.۶۴	۶.۱۳	دوم (۲۰ تا ۲۶ فوریه)
۳۱.۱۴	۱۱.۹۸	۱۲.۳۹	۱۲.۵۹	۱۸.۷	۱۵.۹۵	۱۵.۷۱	سوم (۱۹ تا ۲۵ اگوست)
۸.۷۵	۱۰.۲۸	۱۳.۸۵	۱۳.۳۹	۱۱.۷۴	۱۱.۱۸	۲۱.۸۶	چهارم (۱۸ تا ۲۴ نوامبر)
۱۵.۲۷	۸.۲۰	۹.۲۴	۹.۱۳	۱۰.۸۷	۹.۷۰	۱۲.۶۰	میانگین

(خطای OWA اصلاح شده) / (خطای بهترین موتور مقدماتی - خطای OWA اصلاح شده) \* ۱۰۰ = درصد بهبود OWA اصلاح شده


را در تعدادی از ساعت های هفته به عنوان عامل نامطلوب شناسایی می کند و اثر منفی آن در خروجی را خنثی می نماید. روش OWA اصلاح شده پیشنهادی، در تمامی هفته های تست، بر اساس معیار خطای هفتگی در واحد، می تواند بهتر از تمامی موتورهای مقدماتی و روش های متداول مبتنی بر ترکیب اطلاعات عمل نماید. در واقع، همان طور که در آخرین ستون جدول (۱) نشان داده شده است، استفاده از OWA اصلاح شده به طور میانگین باعث ۱۵.۱۷٪ بهبود خطای پیش بینی نسبت به بهترین موتور پیش بین مقدماتی شده است. همچنین میانگین خطای روش OWA اصلاح شده (۸.۲۰٪)، کمتر از خطای سایر روش های ترکیب اطلاعات است. عملکرد روش OWA اصلاح شده بر اساس معیار واریانس خطای هفتگی نیز با دیگر روش های ترکیب اطلاعات مقایسه شده است. نتایج جدول (۲) نشان می دهد که OWA اصلاح شده به خوبی توانسته است منجر به واریانس خطای کمتری نسبت به سایر روش های ترکیب اطلاعات شود.

جدول (۲): واریانس خطای هفتگی (٪) روش های مختلف پیش بینی

OWA اصلاح شده	انتگرال فازی چکوئیت	OWA	هفته تست
۰.۰۰۳۰	۰.۰۰۲۹	۰.۰۰۳۰	اول
۰.۰۰۱۹	۰.۰۰۱۷	۰.۰۰۱۹	دوم
۰.۰۱۱۰	۰.۰۱۲۵	۰.۰۱۳۳	سوم
۰.۰۰۶۹	۰.۰۰۹۹	۰.۰۰۹۷	چهارم
۰.۰۰۵۷	۰.۰۰۶۸	۰.۰۰۷۰	میانگین

همان طور که جدول (۱) نشان می دهد، عملکرد موتورهای پیش بین مقدماتی، از نظر معیار خطای هفتگی در واحد، در هفته های مختلف نسبت به هم تغییر می کند: در سه هفته، شبکه عصبی ANN، و در یک هفته دیگر ARMA عملکرد بهتری نشان می دهد. رتبه های دوم و سوم بهترین موتور پیش بین مقدماتی نیز در هفته های مختلف فرق می کند. بدین ترتیب، نشان داده می شود که یک روش خاص به تنهایی نتوانسته است از تمامی روش های دیگر بهتر عمل نماید. بر اساس نتایج جدول (۱)، روش های مبتنی بر ترکیب اطلاعات می توانند در اکثر مواقع جواب هایی با خطای هفتگی در واحد کمتری نسبت به موتورهای پیش بین مقدماتی ارائه دهند؛ در طول سه هفته اول، هر سه الگوریتم مبتنی بر ترکیب اطلاعات از موتورهای پیش بین مقدماتی خود بهتر عمل نموده اند. خاطر نشان می کنیم که در این مدت عملکرد OWA و OWA اصلاح شده تقریباً مشابه یکدیگر است؛ چرا که خطای سه موتور مقدماتی تقریباً برابر با یکدیگر هستند. لذا، عموماً عامل نامطلوبی شناسایی نمی شود.

در هفته تست چهارم، روش های متداول ترکیب اطلاعات (OWA و انتگرال فازی چکوئیت) از دو موتور مقدماتی (ANN و ANFIS) بدتر عمل می نماید که احتمالاً به خاطر آن است که خطای موتورهای مقدماتی به شدت با یکدیگر متفاوت است (خطای ARMA، در مقیاس خطای هفتگی در واحد، تقریباً دو برابر ANN و ANFIS است). در طرف مقابل، OWA اصلاح شده پیشنهاد شده، همچنان بهتر از تمامی پیش بینی های مقدماتی عمل می نماید؛ چرا که ARMA



شکل (۳): مقادیر واقعی قیمت بازار (خطوط پر رنگ) و پیش‌بینی شده توسط OWA اصلاح شده (خطوط کمرنگ) در هفته تست سوم

### ضمایم: موتورهای پیش‌بینی مقدماتی

در این بخش، چگونگی پیکربندی موتورهای پیش‌بینی مقدماتی مختصراً شرح داده خواهد شد. ما از موتورهای پیش‌بین مقدماتی ANN، ANFIS و ARMA استفاده نموده‌ایم چرا که عملکرد خوبی در پیش‌بینی سری زمانی قیمت از خود نشان داده‌اند. عملکرد این موتورهای پیش‌بین متاثر از ساختار مدل‌ها و متغیرهای ورودی آن‌هاست. ورودی‌های این موتورهای پیش‌بین بر اساس الگوریتم پیشنهاد داده شده در [۲۷]، یعنی PMI-based mRMR، انتخاب می‌شوند. جهت حفظ سادگی فرایند، تنها سری زمانی قیمت به عنوان داده ورودی انتخاب شده است. ۱۶۸ تاخیر گذشته سری زمانی قیمت به عنوان متغیرهای ورودی کانیددا انتخاب شده‌اند.

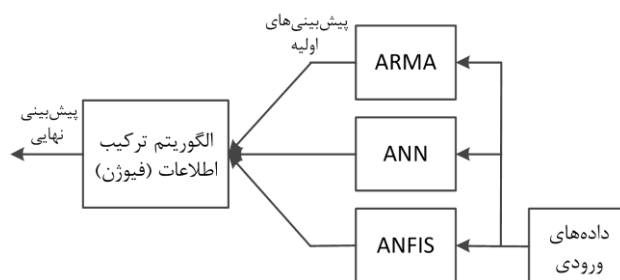
ساختار هر کدام از مدل‌های پیش‌بین مقدماتی بر اساس یک جستجوی جامع انتخاب شده است. جدول ۳ پارامترهای قابل تنظیمی را نشان می‌دهد که ساختار هر کدام از مدل‌های فوق را مشخص می‌کند. به عنوان مثال، ساختار شبکه‌های عصبی چند لایه توسط تعداد نورون‌های لایه ورودی، تعداد نورون‌های لایه (های) مخفی و الگوریتم یادگیری مشخص می‌شود. تاکنون، برای تعیین این پارامترها، فرایندی مورد قبول همگان پیشنهاد نشده است. بنابراین، به منظور حفظ سادگی، از یک جستجوی جامع برای انتخاب این پارامترها استفاده شده است: در این راستا، ابتدا سری‌های زمانی ورودی به سه دسته داده‌های آموزش، اعتبار سنجی و تست (آزمون) تقسیم می‌شوند. ما برای هر کدام از پارامترهای قابل تنظیم یک دامنه جستجو تعریف نموده‌ایم (ستون سوم جدول ۳). به کمک داده‌های موجود در دسته آموزش، برای هر کدام از حالات مختلف ممکن، موتورهای پیش‌بینی مقدماتی را یک بار آموزش می‌دهیم. بدین ترتیب، تعدادی مدل آموزش دیده در اختیار خواهیم داشت. مدلی که بتواند بهترین پیش‌بینی را در دوره اعتبار سنجی ارائه دهد، به عنوان مدل اصلی برای پیش‌بینی متغیر هدف در دوره تست استفاده می‌شود.

پیش‌بینی حاصل از الگوریتم OWA اصلاح شده در هفته تست سوم به صورت گرافیکی در شکل (۳) نمایش داده شده است. مشاهده می‌شود که روش OWA اصلاح شده توانسته است پیش‌بینی‌های مقدماتی را با ضرایب مناسب با یکدیگر ترکیب نماید. به عنوان مثال، در روز اول می‌توان دید که اگرچه هیچکدام از پیش‌بینی‌های مقدماتی خاکستری رنگ نتوانسته اند قیمت را به خوبی پیش‌بینی نمایند، OWA اصلاح شده توانسته است ضرایب مناسبی انتخاب نماید به گونه‌ای که پیش‌بینی ترکیب شده نهایی خطای بسیار کمتری نسبت به هر کدام از پیش‌بینی‌های مقدماتی دارد.


عملکرد چارچوب پیشنهادی و الگوریتم ترکیب اطلاعات پیشنهادی نشان می‌دهد که این روش در افزایش صحت پیش‌بینی‌ها موثر بوده است. بنابراین، جای شگفتی نخواهد بود که این روش‌های مبتنی بر ترکیب اطلاعات، اگر ورودی‌هایی با صحت بالاتر به آن‌ها ارائه گردند، بتوانند نتایج بهتری نیز نشان دهند.

### ۵- نتیجه

در این مقاله، یک چارچوب جدید برای هیبرید کردن چند موتور پیش‌بین متفاوت ارائه شد که بر اساس مفهوم ترکیب اطلاعات عمل می‌نماید. در چارچوب پیشنهادی ما، سه پیش‌بینی مستقل از متغیر هدف توسط سه موتور پیش‌بینی ANN، ANFIS و ARIMA ایجاد می‌شود که توسط یک الگوریتم ترکیب اطلاعات با یکدیگر ترکیب می‌شوند تا یک پیش‌بینی واحد در خروجی ایجاد گردد. همچنین، یک الگوریتم ترکیب اطلاعات جدید با نام OWA اصلاح شده نیز ارائه شد که بر خلاف OWA اصلی از میزان خطای ورودی‌های خود بازخورد دریافت می‌نماید. از چارچوب و الگوریتم پیشنهادی فوق برای پیش‌بین قیمت بازار برق اسپانیا استفاده نمودیم. نتایج شبیه‌سازی‌ها نشان می‌دهند که روش‌های پیشنهادی می‌توانند پیش‌بینی‌های با صحت بهتری نسبت به موتورهای پیش‌بین مقدماتی خود ارائه دهند.



شکل (۱): چارچوب پیشنهادی برای موتور پیش‌بین



شکل (۲): چگونگی تقسیم داده‌ها به منظور آموزش، اعتبارسنجی و انتخاب موتورهای پیش‌بینی



جدول (۳): پارامترهای قابل کنترل در ساختار موتورهای پیش‌بین

مقدماتی		
موتور پیش بینی	پارامترهای قابل تنظیم	دامنه جستجو تعریف شده پارامترها
ARMA	تعداد تاخیرهای خود بازگشتی	۴.۷.۱۰.۱۳.۱۶.۲۰
	تعداد تاخیرهای میانگین متحرک	۴.۷.۱۰.۱۳.۱۶.۲۰
شبکه های عصبی چند لایه ANN	تعداد ورودی ها	۳ تا ۱۰
	تعداد نورون ها	۳ تا ۱۰ و ۱۰.۱۵.۲۰.۲۵
	تعداد لایه‌های پنهان	۱
ANFIS	الگوریتم آموزش	Levenberg Marquardt
	تعداد ورودی ها	۳ تا ۹
	تعداد قانونها	۴.۸.۱۶.۳۲

## مراجع

- [11] M. Shafie-khah, M. P. Moghaddam, and M. K. Sheikh-El-Eslami, "Price forecasting of day-ahead electricity markets using a hybrid forecast method," *Energy Convers. Manag.*, vol. 52, no. 5, pp. 2165–2169, May 2011.
- [12] A. Krogh and J. Vedelsby, "Neural Network Ensembles, Cross Validation, and Active Learning," *Adv. Neural Inf. Process. Syst.*, vol. 1, pp. 231–238, 1994.
- [13] L. Wu and M. Shahidehpour, "A Hybrid Model for Day-Ahead Price Forecasting," *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1519–1530, 2010.
- [14] A. Asrari and M. H. Javidi, "Application of a New Hybrid Method for Day-Ahead Energy Price Forecasting in Iranian Electricity Market," *Iran. J. Electr. Electron. Eng.*, vol. 8, no. 4, pp. 322–328, 2012.
- [15] S. Fan, C. Mao, and L. Chen, "Next-day electricity-price forecasting using a hybrid network," *IET Gener. Transm. Distrib.*, vol. 1, no. 1, pp. 176–182, 2007.
- [16] P. Areekul, T. Senjyu, and H. Toyama, "A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting in Deregulated Market," *IEEE Trans. Power Syst.*, vol. 25, no. 1, pp. 524–530, 2010.
- [17] W. Lucien, "Some terms of reference in data fusion," *IEEE Trans. Geosci. Remote Sens.*, vol. 37, no. 3, pp. 1190–1193, 1999.
- [18] J. Llinas and D. L. Hall, *Hand Book of Multisensor Data Fusion*. CRC Press, Boca Raton London, New York, Washington DC, 2001.
- [19] D. F. Tello, T. Gamarra, F. Bastos-Filho, M. Sarcinelli-Filho, C. M. Soriay, and R. Carelly, "Optical Flow Calculation Using Data Fusion with Decentralized Information Filter," in *Proceedings of the 2005 IEEE International Conference on Robotics and Automation Barcelona*.
- [20] E. Stella, G. Cicirelli, A. Distanto, and I. Elaborazione, "Position Estimation for a Mobile Robot using Data Fusion 2 Odometer Estimation Model."
- [21] B.-S. Chen, C.-Y. Yang, F.-K. Liao, and J.-F. Liao, "Mobile Location Estimator in a Rough Wireless Environment Using Extended Kalman-Based IMM and Data Fusion," *IEEE Trans. Veh. Technol.*, vol. 58, no. 3, 2009.
- [22] R. R. Yager, "On Ordered Weighted Averaging Aggregation Operators in Multicriteria Decisionmaking," *IEEE Trans. Man Cybern.*, vol. 18, no. 1, pp. 183–190, 1988.
- [23] R. R. Yager, J. Kacprzyk, and G. Beliakov, *Recent Developments in the Ordered Weighted Averaging Operators: Theory and Practice*. Springer-Verlag Berlin Heidelberg, 2011.
- [24] D. Filev and R. R. Yager, "Learning OWA operator weights from data," *IEEE World Congr. Comput. Intell. Fuzzy Syst.*, pp. 468–473, 1994.
- [25] T. Murofushi and M. Sugeno, "An interpretation of fuzzy measures and the choquet integral as an integral with respect to a fuzzy measure," *Fuzzy Sets Syst.*, vol. 29, pp. 201–227, 1989.
- [26] L. M. de Campos, M. T. Lamata, and S. Moral, "A unified approach to define fuzzy integrals," *Fuzzy Sets Syst.*, vol. 39, no. 1, pp. 75–90, Jan. 1991.
- [27] A. Darudi, S. Rezaeifar, and M. H. Javidi, "Partial Mutual Information Based Algorithm For Input Variable Selection," in *13th International Conference on Environment and Electrical Engineering (EEEIC13)*, Wroclaw, Poland, 2013.
- [1] N. Amjady, A. Daraeepour, and F. Keynia, "Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network," *IET Gener. Transm. Distrib.*, vol. 4, no. 3, p. 432, 2010.
- [2] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, and A. K. Sirvastava, "A Novel Approach to Forecast Electricity Price for PJM Using Neural Network and Similar Days Method," *IEEE Trans. Power Syst.*, vol. 22, no. 4, pp. 2058–2065, 2007.
- [3] N. Amjady and M. Hemmati, "energy price forecasting - problems and proposals for such predictions," *IEEE power energy Mag.*, vol. 4, no. 2, pp. 20–29, 2006.
- [4] S. K. Aggarwal, L. M. Saini, and A. Kumar, "Electricity price forecasting in deregulated markets: A review and evaluation," *Int. J. Electr. Power Energy Syst.*, vol. 31, no. 1, pp. 13–22, Jan. 2009.
- [5] J. Contreras, R. Espínola, F. J. Nogales, and A. J. Conejo, "ARIMA Models to Predict Next-Day Electricity Prices," *IEEE Trans. Power Syst.*, vol. 18, no. 3, pp. 1014–1020, 2003.
- [6] R. C. Garcia, J. Contreras, M. Van Akkeren, and J. B. C. Garcia, "A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 867–874, 2005.
- [7] A. J. Conejo, M. A. Plazas, R. Espínola, and A. B. Molina, "Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 1035–1042, 2005.
- [8] A. T. Lora, J. M. R. Santos, A. G. Expósito, J. Luis, M. Ramos, and J. C. R. Santos, "Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques," *IEEE Trans. Power Syst.*, vol. 22, no. 3, pp. 1294–1301, 2007.
- [9] J. P. S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, and L. a. F. M. Ferreira, "Short-term electricity prices forecasting in a competitive market: A neural network approach," *Electric Power Syst. Research*, vol. 77, no. 10, pp. 1297–1304, Aug. 2007.
- [10] N. Amjady, "Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network," *IEEE Trans. Power Syst.*, vol. 21, no. 2, pp. 887–896, 2006.