

## پیش بینی کوتاه مدت بار فیدرهای توزیع با استفاده از شبکه عصبی

### Short term load forecasting using artificial neural network

سلیمان فهرستی ثانی<sup>۱</sup>      غضنفر شاهقلیان<sup>۲</sup>      مهران زمانی فر<sup>۲</sup>

۱- کارشناسی ارشد دانشگاه آزاد اسلامی واحد نجف آباد

۲- استادیار دانشکده برق، دانشگاه آزاد اسلامی واحد نجف آباد

#### چکیده

دراقتصاد رقابتي کنونی مسائل مربوط به انرژی الکتریکی از جمله پیش بینی، بهینه سازی، ذخیره سازی و ... انرژی الکتریکی از اهمیت بالایی برخوردار می باشد. همچنین کلیه فعالیت های زندگی امروزه به تولید برق وابسته می باشد. از آنجاییکه انرژی الکتریکی در حد جزئی قابلیت ذخیره سازی دارد لذا تولید بیشتر یا کمتر از میزان مصرف خساراتی در پی دارد از طرف دیگر پیش بینی بار روزانه در شرکت های توزیع که به منظور ارائه به شرکت مدیریت شبکه (DMS) و همچنین به منظور اتخاذ روش مناسب مدیریت بار می باشد امری جدا ناپذیر در سیستم های توزیع محسوب می گردد. با توجه به تأثیر پذیری الگوهای بار از عوامل مختلفی مانند عوامل آب وهوایی، اقتصادی و اجتماعی، پیش بینی دقیق بار امر دشواری می باشد. به همین دلیل در سال های اخیر استفاده از الگوریتم های هوشمند نسبت به دیگر روش ها کاربرد بیشتری در مسائل پیش بینی پیدا نموده است. در این پروژه پیش بینی بار کوتاه مدت روزهای سال به روش شبکه عصبی صورت گرفته استو نتایج آن با روش رگرسیون مقایسه گردیده است. با توجه به رفتارهای متفاوت بار در روزهای مختلف، روش های گوناگونی برای پیش بینی بار اتخاذ شده است که با بررسی های انجام شده بر روی روش های مختلف پیش بینی بار، روش جدیدی جهت پیش بینی کوتاه مدت بار به صورت ساعتی، در شبکه توزیع ارائه می گردد. با توجه به نتایج بدست آمده الگوریتم شبکه عصبی پیشنهادی مقدار مناسبی از بار را پیش بینی می نماید.

**کلمات کلیدی:** پیش بینی - بار ساعتی - شبکه عصبی - آنالیز مولفه اصلی - ضریب همبستگی - دسته بندی داده ها

#### مقدمه

در ابعاد بزرگ امکان پذیر نمی باشد. بنابراین پیش بینی دقیق مصرف بار در دوره خاص می تواند در استفاده اقتصادی از انرژی الکتریکی نقش مهمی ایفا نماید. پیش بینی صحیح بار علاوه بر صرفه جویی در هزینه های سرمایه گذاری، امکان برنامه ریزی بهتر برای توسعه نیروگاه ها و شبکه های انتقال و توزیع را فراهم می کند. اطلاع از رشد بار و تقاضای برق یکی از مهمترین مسائل حائز اهمیت در بهره برداری و توسعه بهینه شبکه برق می باشد. بدلیل تغییر بار در طول روز بازه هایی از

با توجه به اینکه هدف اصلی شبکه های توزیع برق پاسخگویی به تقاضای بار با کیفیت مطلوب می باشد و این تقاضای روزافزون، نیاز به یک برنامه ریزی آینده نگر دارد. در نتیجه اطلاع از بار شبکه در سال های آتی از اهمیت بالایی برخوردار می باشد. در سالهای اخیر بازار تقاضای جهانی برق نسبت به دیگر انرژی ها از رشد بیشتری برخوردار بوده است. لذا میزان افزایش انرژی برق در کشور اهمیت بالایی داشته از طرف دیگر قابلیت ذخیره سازی انرژی الکتریکی با توجه به تکنولوژی های موجود

### ۳) روش کاربری اراضی

روش کاربری اراضی، اطلاعات و آمار کاربرها و تراکم ساخت و ساز در نقاط مختلف شهر در سال های آینده را بررسی نموده و با توجه به نوع بارها (خانگی، صنعتی، خدماتی و کشاورزی) به پیش بینی بار می پردازد [2].

### ۴) شبکه عصبی

شبکه عصبی جزو روشهای جدید برآورد بار و انرژی الکتریکی می باشد که با اقتباس از سیستم شبکه عصبی و مغز بشر و به کمک رایانه قابل محاسبه می باشد. این روش بیشتر برای پیش بینی بار بسیار کوتاه مدت و کوتاه مدت مورد استفاده قرار گرفته است و استفاده از آن در پیش بینی بار بلند مدت در دست بررسی می باشد [3].

### پیش بینی بار از دیدگاه زمان

از دیدگاه مقیاس زمانی، پیش بینی بار به چهار گروه زیر تقسیم می گردد:

- ۱- بسیار کوتاه مدت (فواصل زمانی چند دقیقه تا یک ساعت)
- ۲- کوتاه مدت (فواصل زمانی یک ساعت تا چند روز که هدف این مقاله نیز می باشد)
- ۳- میان مدت (فواصل زمانی یک ماه تا چند سال)
- ۴- بلند مدت (فواصل زمانی چند سال تا چند دهه)

### شبکه عصبی

همانطور که پیش از این اشاره شد، برای پیش بینی بار روزانه روشهای مختلفی توسط محققین بکار گرفته شده است. برخی محققین از روشهای سری زمانی و رگرسیون خطی یا روشهای تلفیقی آنها با سیستم خبره استفاده نموده اند. مرجع [4] از سری زمانی جهت پیش بینی بار استفاده نموده است که تجربیات اپراتور خبره را نیز بعنوان یکی از پارامترهای مدل در نظر می گیرد. در این مرجع از هشت دسته بندی برای بارها (شنبه ها، یکشنبه ها تا چهارشنبه ها، پنجشنبه ها، جمعه ها، تعطیلات عمومی فصل گرم و تعطیلات عمومی فصل سرد) استفاده شده است.

روز را جهت تعیین میزان مصرف بار در آن بازه انتخاب می نماییم.

### پیش بینی

از سالها پیش، پیش بینی بار در بین دانشگاهیان و محققین مورد توجه قرار گرفته است از این رو تکنیکهای پیش بینی متنوعی در این حوزه پیشنهاد شده است که این روش ها به طور کلی به چهار دسته زیر تقسیم می شوند [1].

۱. روش مصرف نهایی (End Use)
۲. روش های زمانی
۳. روش کاربری اراضی (Land Use)
۴. روشهای نوین مانند شبکه عصبی (Artificial Neural Networks) و ...

### ۱) روش مصرف نهایی

این روش مبتنی بر اطلاعات تجهیزات مصرف کننده بار (مانند کولر، تلویزیون، کامپیوتر و...) و نحوه ی رشد تعداد آنها در سالهای آینده می باشد. این روش نیاز به اطلاعات بسیار گسترده و وسیعی دارد که گاه محاسبه بار را غیر ممکن می سازد.

### ۲) روش های زمانی

در این روش اطلاعات و آمار و رفتار بار در سال های گذشته جهت پیش بینی بار استفاده می گردد. این روش، خود به دو دسته تقسیم می گردد:

- روش سری زمانی
- روش لجستیکی

اگر بار مورد بررسی دارای روند افزایشی بدون محدودیت در بلند مدت باشد از سری زمانی (روش رگرسیون) استفاده می گردد. اما اگر رشد بار دارای سقف باشد برای مدلسازی از روش لجستیکی موسوم به روش منحنی S شکل استفاده می نماییم. از روش لجستیکی بدلیل در نظر گرفتن چگالی بار مشخص جهت پیش بینی بار در شبکه های توزیع بیشتر استفاده می گردد.

شده است. دسته بندی مناسب داده ها میزان خطای پیش بینی را کاهش می دهد.

### دسته بندی داده ها

عناصر غیر قطری ماتریس کوواریانس بیان گر میزان همبستگی دو عنصر از ماتریس کوواریانس به یکدیگر می باشد. بنابراین ماتریس کوواریانس می تواند نقش مهمی در تقسیم بندی داده های ورودی به شبکه عصبی ایفا نماید. برای نرمالیزه کردن ارتباط میان عناصر ماتریس کوواریانس می توان از رابطه ذیل استفاده نمود:

$$R(i, j) = \frac{C(i, j)}{\sqrt{C(i, i) \cdot C(j, j)}}$$

که در این رابطه خواهیم داشت:

$R(i, j)$ : عنصر سطر  $i$  ام و ستون  $j$  ام ماتریس ضرایب همبستگی

$C(i, j)$ : عنصر سطر  $i$  ام و ستون  $j$  ام ماتریس کوواریانس  
 $C(i, i)$  و  $C(j, j)$ : عناصر قطری سطر و ستون  $i$  ام و  $j$  ام ماتریس کوواریانس

با توجه به ویژگی ماتریس ضرایب همبستگی می توان شاخص مناسبی را جهت گروه بندی داده ها در نظر گرفت به عنوان مثال شاخص زیر را می توان تعریف نمود:

$$SR_i = \sum_{j=1}^n R(i, j)$$

که در این رابطه:

$SR_i$ : شاخص تعیین گروه داده های سطر  $i$  ام  
 $R(i, j)$ : ضریب سطر  $i$  ام و ستون  $j$  ام ماتریس ضرایب همبستگی

$n$ : تعداد روزهای داده های یادگیری (تعداد کل سطر ها)  
بر اساس این شاخص جمع کلیه مقادیر هر سطر ماتریس ضرایب همبستگی می تواند بیانگر شاخص گروه بندی داده ها قرار گیرد. شرط توقف گروه بندی نیز تعداد دسته ها در نظر گرفته می شود که عدد پیشنهادی در این مقاله دسته های حداقل ۱۵ عضو می باشد. همچنین باید توجه نمود که امکان دسته بندی همزمان داده های تمامی سالها وجود ندارد زیرا ممکن است داده های

در مرجع [5] یک مدل شبکه عصبی متشکل از دو شبکه خودسازمانده، که یکی بالای دیگری قرار دارد استفاده نموده است. یکی از شبکه های اطلاعات را به صورت مناسبی دسته بندی کرده و به عنوان داده های ورودی به شبکه دیگر ارسال می نماید از این مدل جهت پیش بینی بار ساعتی در طول ۲۴ ساعت بعد از دوره آموزش مورد ارزیابی قرار گرفته است.

در مرجع [6] جهت پیش بینی دقیقتر بار چندین تکنیک شامل، آنالیز Gary، آنالیز یادگیری پسخور تصادفی با نرخ یادگیری پویا و مونتوم را با یکدیگر تلفیق نموده و برای پنج شبکه تا مدت زمانی پنج روز بعد، بار شبکه ها را پیش بینی نموده است.

برخی دیگر نیز با شناسایی روزهای وابسته به روز مورد بررسی و یا بررسی دیگر عوامل تاثیر گذار بر مصرف بار مثلا درجه حرارت هوا، رطوبت هوا، سرعت باد، پوشش ابر، ساعات آفتابی، میزان بارش و ... سعی در پیشبینی دقیقتر بار نموده اند [7].

ساختار شبکه عصبی برگرفته از مدل هایی است که بشر برای مغز انسان و سلول های عصبی آن متصور است. در دهه های گذشته، تحقیق زیادی بر روی کاربرد تکنیک های هوش مصنوعی (AI) برای مساله پیش بینی بار انجام شده اند. در میان این تکنیک ها، مدل هایی که بیشترین توجه را به سوی خود جلب نموده اند، شبکه های عصبی مصنوعی (ANNs) هستند. اولین گزارش ها در مورد کاربرد این روش در مسائل پیش بینی بار در اواخر دهه ۱۹۸۰ و اوایل دهه ۱۹۹۰ منتشر شد و این روش بدلیل قابلیت مطلوب آن در مدلسازی غیر خطی به شکل گسترده در پیش بینی بار سیستم های الکتریکی مورد استفاده قرار گرفته است [8].

با توجه به اینکه یکی از مسائل بسیار مهم در شبکه های عصبی دسته بندی داده های اولیه می باشد و در اکثر مقالات به چاپ رسیده، دسته بندی داده ها از پیش تعیین شده بوده است بدین معنی که شیوه خاصی جهت تفکیک داده ها ارائه نشده و بنا به ایام سال به چند دسته تقسیم شده است. در این مقاله با توجه به ضریب همبستگی روشی جهت گروه بندی داده ها در نظر گرفته

$$7. T = [\emptyset_1 \quad \emptyset_2 \quad \dots \quad \emptyset_1 \quad \dots \quad \emptyset_k]$$

$$s. t. \quad \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i} \geq 0.9$$

محاسبه ماتریس کاهش یافته داده ها:

$$8. A_{PCA} = A_a \cdot T$$

اعمال معکوس (ترانهاده) ماتریس انتقال جهت محاسبه داده های تقریبی:

$$9. A' = A_{PCA} \cdot T^t$$

می توان ثابت نمود که بدلیل عمود بودن بردارهای تشکیل دهنده ماتریس انتقال، معکوس این ماتریس با ترانهاده آن برابر است. از ویژگی مهم این روش میتوان به سادگی محاسبات مربوط به تعیین گروه بندی داده ها اشاره نمود [10].

#### ساختار شبکه عصبی

در این مقاله ساختار مورد استفاده، یک شبکه عصبی چند لایه (دو لایه) انتخاب شده است. لایه ها از نوع سیگموئید، و تعداد نرون ها پنج عدد در نظر گرفته شده است. برای آموزش این شبکه داده های دوسال متوالی مجموع باساعتی پستهای توزیع شهرستان اصفهان (سال ۸۶ و ۸۷) استفاده شد و مقادیر بار سال ۸۸ به عنوان داده های آزمایش روش استفاده گردید. در این مقاله داده های ورودی به شبکه عصبی با استفاده از آنالیز مولفه اصلی (PCA) فشرده سازی می گردند این عمل باعث کاهش ابعاد بردار ورودی و در نتیجه کاهش پیچیدگی مسئله شده و زمان آموزش نیز کاهش می یابد و نتایج شبکه عصبی را نیز بهبود می بخشد. فلوچارت روبرو روند کلی روش پیش بینی ارائه شده را نشان می دهد.

بهاریک سال با داده های زمستان سال دیگری در یک گروه قرار بگیرند که از نظر منطقی صحیح نمی باشد لذا دسته بندی هر سال به صورت جداگانه انجام شده و سپس اشتراک میان دسته بندی ها شناسایی می گردد [9].

#### روش تحلیل مولفه اصلی (PCA)

#### Principal component analysis

عملکرد اصلی این روش کاهش ابعاد ماتریس داده با استفاده از کشف روابط پنهان میان متغیرهای مختلف می باشد که باعث کاهش فضای مورد نیاز در حافظه کامپیوتر، زمان پردازش و حل مساله می گردد.

مراحل روش تحلیل اجزاء اصلی به صورت ذیل می باشد: با در نظر گرفتن ماتریس A به عنوان ماتریس داده شامل n ستون که در اینجا ۲۴ ساعت شبانه روز می باشد و r سطر که تعداد روزهای هر دسته محسوب میگردد خواهیم داشت:

$$A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{r1} & \dots & a_{rn} \end{bmatrix}$$

محاسبه میانگین ردیف ها:

$$1. \bar{a}_j = \frac{1}{r} \sum_{i=1}^r a_{i,j}$$

تفریق داده ها از میانگین (نرمالیزه نمودن):

$$2. A_a = \{Row_i(A) - \bar{a}\}_{i=1}^n$$

محاسبه ماتریس کواریانس:

$$3. C = \frac{1}{r} (A_a^T \cdot A_a)$$

محاسبه مقادیر ویژه:

$$4. \lambda = \{\lambda_1 \quad \lambda_2 \quad \dots \quad \lambda_n\}$$

محاسبه بردار ویژه متناظر با هر مقدار ویژه:

$$5. \emptyset = \{\emptyset_1 \quad \emptyset_2 \quad \dots \quad \emptyset_n\}$$

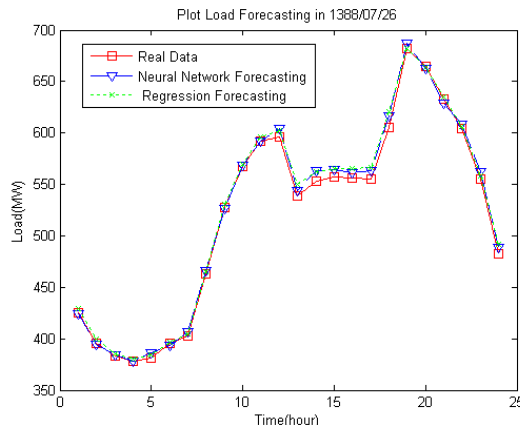
مرتب سازی بردار های ویژه متناظر با مقدار ویژه بزرگتر:

$$6. \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n, \emptyset_1 \geq \emptyset_2 \geq \dots \geq \emptyset_n$$

انتخاب تعداد محدودی از بردار های ویژه به نحوی که شرط زیر برقرار باشد (ماتریس انتقال):

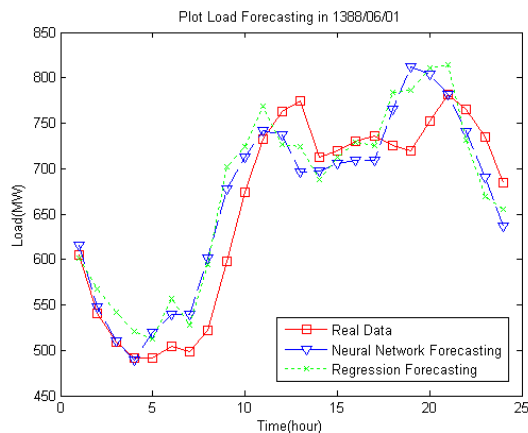
شکل (۱) منحنی بار واقعی و پیش بینی شده را در ۲۶ ام مهر ماه ۸۸ نشان می دهد که با توجه به نتایج، خطای حاصل در کمترین مقدار قرار دارد.

شکل (۲) منحنی بار واقعی و پیش بینی شده را در ۱۱ شهریور ماه ۸۸ نشان می دهد که خطای حاصل در بیشترین مقدار می باشد و در ساعاتی از روز روش رگرسیون نتیجه بهتری نسبت به شبکه عصبی دارد.



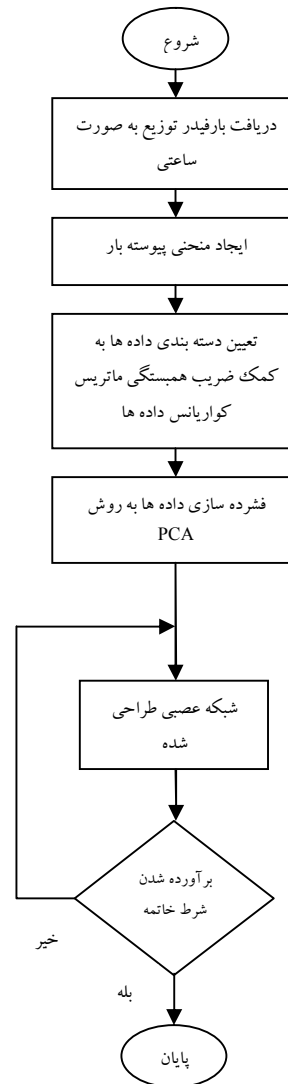
شکل (۱): نمودار بار واقعی و پیش بینی شده در تاریخ

۸۸/۰۷/۲۶



شکل (۲): نمودار بار واقعی و پیش بینی شده در تاریخ

۸۸/۰۶/۰۱



## معیارهای عملکرد

در اکثر مقالات، فقط میانگین درصد قدرمطلق خطا (MAPE) را بیان می نمایند هر چند MAPE یک استاندارد در صنعت تامین انرژی الکتریکی است اما در صورتی که تابع جریمه خطی باشد (خطی بودن نمودار درصد خطا) به تنهایی جهت مقایسه کافی می باشد. با توجه به اینکه تابع جریمه در مسائل پیش بینی بار غیر خطی می باشد در این مقاله برای سنجش بهتر پیش بینی بار از معیارهای میانگین قدر مطلق خطا (MAE) و میانگین مجموع مربعات خطا (MSE) نیز در کنار معیار MAPE استفاده شده است و همچنین نتایج بدست آمده با نتایج مدل شبیه سازی رگرسیون خطی مقایسه شده اند [11].

شماره دسته	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	برآیند
تعداد دسته (سال ۸۷)	۶۵	۵۴	۵۲	۴۱	۳۸	۳۳	۲۹	۲۰	۱۷	۱۷	۳۶۶
درصد خطای شبکه عصبی	MAPE	۱,۵۷	۱,۵۵	۱,۶۳	۱,۷۰	۱,۹۸	۱,۸۵	۲,۰۲	۲,۱۸	۲,۲۳	۱,۶۷
	MAE	۱,۸۰	۲,۰۰	۲,۱۰	۲,۷۰	۳,۰۰	۳,۱۰	۳,۲۰	۳,۱۰	۳,۵۰	۲,۵۰
	MSE	۱,۷۰	۱,۸۰	۲,۱۰	۲,۵۰	۲,۶۰	۲,۸۰	۲,۷۰	۲,۹۰	۳,۱۰	۲,۳۰
درصد خطای رگرسیون خطای	MAPE	۱,۸۱	۱,۸۵	۱,۸۹	۲,۱۲	۲,۱۴	۲,۱۵	۲,۲۰	۲,۴۲	۲,۴۳	۲,۰۵
	MAE	۲,۵۰	۲,۸۰	۲,۳۰	۲,۳۰	۳,۳۰	۳,۴۰	۴,۰۰	۳,۸۰	۳,۸۰	۳,۰۰
	MSE	۲,۲۰	۲,۳۰	۲,۴۰	۲,۰۰	۲,۸۰	۲,۹۰	۳,۲۰	۳,۳۰	۳,۴۰	۲,۶۰

جدول (۱): نتایج درصد خطای شبکه توزیع شهرستان اصفهان در سال ۸۸

### نتیجه گیری

در این مقاله با توجه به داده های ساعت به ساعت دو سال (۸۶ و ۸۷) مجموع بار پستهای توزیع شهرستان اصفهان، بار سال ۸۸ این شهرستان پیش بینی گردید. با توجه به نتایج بدست آمده و میانگین درصد خطای مطلق و دیگر معیار های ارائه شده در این مقاله میتوان نتیجه

گرفت که استفاده از این روش برای پیش بینی کوتاه مدت بار بسیار موثر و کارآمد می باشد. بدیهی است با در اختیار داشتن بار سالهای دیگر و همچنین لحاظ نمودن پارامترهایی چون دمای هوا می توان به دقت بیشتری دست یافت.

### مراجع

- [1] H.L.Willis et al., "Load Transfer Coupling Regression Curve Fitting Load Forecasting", IEEE Trans. Power Engineering Review, PP.1070, May 1984.
- [2] H.L.Willis M.V Engel., "Spatial Load Forecasting", IEEE Computer Application in Power, PP.40-43, 1995.
- [3] خلیل بانان علی عباسی، الهویردی رضائی آغ اوغلان، "پیش بینی بار کوتاه مدت با استفاده از شبکه عصبی - فازی"، یازدهمین کنفرانس شبکه های توزیع نیروی برق، ۱۳۸۵.
- [4] Amjady, N., "Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability", IEEE Trans. Power Systems, Vol. 16, No.4, PP.798-805, November 2001.
- [5] Carpintero, O.A.S. Alves Da Silva, A.P., "A Hierarchical Neural Model in Short-Term Load Forecasting", Conference Publications, Vol. 6, No.3, PP.241-246, July 2000.
- [6] Huang, H.G., Hwang, R.C., Hsieh, J.G., "A New Artificial Intelligent Peak Power Load Forecaster Based On Non-Fixed Neural Networks", Electrical Power Energy Systems, 24, PP.245-250, March 2002.

- [7] Saini, L.M., Soni, M.K., "Artificial Neural Networks Based Peak Load Forecasting Using Conjugate Gradient Methods", IEEE Trans. Power Systems, Vol. 17, No.3, PP.907-912, August 2002.
- [8] Hippert, H.S., Pedreira, C.E., Castro, S.R., "Neural Networks For Short-Term Load Forecasting: A Review And Evaluation", IEEE Trans. Power Systems, Vol. 16, No.1, PP.44-55, 2001.
- [9] Antti, M., Maija, R., Sami, R., Pertti, J., "Customer Classification And Load Profiling Method for Distribution Systems", IEEE Trans. PowerDelivery, Vol. 26, No.3, PP.1755-1763, July 2011.
- [10] Gonzalo, M., Georgios, B.G., "Robust PCA As Bilinear Decomposition With Outlier-Sparsity Regularization", IEEE Trans. Signal Processing, Vol. 60, No.10, PP.5176-5190, October 2012.
- [11] Deihimi, A., Showkati, H., "Application Of Echo State Networks In Short-Term Electric Load Forecasting", Energy, PP.327-340, 2012.