

دانشگاه صنعتی شهرود

دانشکده برق و رباتیک

گروه قدرت

پیش‌بینی بارکوتاه مدت با استفاده از شبکه‌های عصبی مصنوعی

دانشجو:

مهرداد گودرزی

استاد راهنما:

دکتر مهرداد بانزاد

استاد مشاور:

دکتر محسن اصیلی

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

شهریور ۱۳۹۲

تقدیر و تشکر

خدایا تو را سپاس

خدایا تو را سپاس به پاس توفیق آگاهی که به من و دیعه دادی. خدایا همچون گذشته به من قدرتی عطا کن تا به استقبال آینده‌ایی روشن پیش روم، صبر مرحمت فرما تا در سختی‌های روزگار دوباره بکوشم. امیدم، رویابی تازه است در انتظار، کمک کن تا بدان دست یابم.

با توجه به عنايات خاصه خداوند متعال، مساعدت و یاری خانواده عزیز، اساتید بزرگوار و دوستان مهربانم، اکنون که پایان نامه خود را به پایان رسانده‌ام بر خود لازم می‌دانم تا مراتب تشکر و قدردانی خود را ابراز نموده و کمال تشکر و امتنان را دارم.

در ابتدا پدرم که همواره بهترین پشتیبانم بوده است. مادرم که محکم‌ترین تکیه‌گاه زندگی‌ام است. خواهر عزیزتر از جانم که زندگیم در کنار او معنی پیدا می‌کند.

استاد ارجمند، آقای دکتر مهدی بازیاد که با راهنمایی‌های ارزنده، زحمات بی‌دریغ و تلاش‌های بی‌وقفه‌اشان در تمام مراحل انجام این پروژه، راهگشای اینجانب بودند.

استاد بزرگوارم، آقای دکتر محسن اصلی برای تمام رهنمودها و زحمات فراوانی که به اینجانب ارزانی داشتند.

و در نهایت دوستان عزیزم که محبت‌های بی‌دریغشان هرگز فروکش نمی‌کند: آقایان هاران ندیمی، احسان سعیدی، عطارد محمدی، امین کیانی‌تبار، پرهام ذوالفاری، دکتر محمد معظمی گودرزی، کامران کاشانی، مهدی شیخ‌الملوکی، محسن حیدری و دیگر دوستانم که همواره همراه بی‌منتم بودند. از شرکت توزیع برق و رئیس تحقیقات اداره کل هواشناسی شهرستان مشهد جناب آقای دکتر قرائی به خاطر کمک در گردآوری داده‌های بار و اطلاعات آب و هوایی نهایت تشکر را دارم.

همچنین از اعضای محترم هیئت داوری آقایان دکتر رحیمیان و دکتر حسن‌پور به خاطر حضور در جلسه دفاعیه و رفع اشکالات این پایان‌نامه تشکر و سپاسگزاری می‌کنم.

چکیده:

پیش‌بینی بار کوتاه مدت نقش بسیار مهمی در برنامه‌ریزی، بهره‌برداری و کنترل سیستم‌های قدرت دارد. پیش‌بینی بار دقیق، باعث بهبود تصمیم‌گیری‌های عملیاتی در مورد برنامه‌ریزی تعمیرات و نگهداری، تخصیص ذخیره مطمئن، برنامه‌ریزی ورود و خروج واحدها، توزیع اقتصادی و ... می‌شود. پیش‌بینی دقیق بار کوتاه مدت با توجه به عوامل متعدد موثر بر بار، از قبیل شرایط آب و هوایی، تغییرات دوره‌ای روزانه، هفتگی، فصلی و عوامل اتفاقی که دارای روابط پیچیده غیرخطی با بار هستند، از پیچیدگی‌های خاص برخوردار می‌باشد و کار بسیار دشواری است.

برای حل مشکلات فوق در این پایان‌نامه پیش‌بینی بار کوتاه مدت، با استفاده از شبکه‌های عصبی مصنوعی انجام می‌شود. شبکه‌های عصبی مصنوعی قادرند روابط غیرخطی دقیق را از میان متغیرهای ورودی، با استفاده از داده‌های آزمایشی استخراج نمایند. هدف این پایان‌نامه کم کردن خطای مسئله پیش‌بینی بار کوتاه مدت و به خصوص بهبود دقت پیش‌بینی بار روزهای خاص با استفاده از یک ساختار مناسب شبکه عصبی مصنوعی و همچنین شناخت و انتخاب موثرترین عوامل تاثیرگذار بر بار به منظور استفاده در ورودی‌های شبکه عصبی می‌باشد.

جهت رسیدن به این مقصود شبکه عصبی پیش‌خور با الگویتم آموزشی پس‌انتشار مورد آزمایش قرار گرفت و نتایج خوبی به دست آمد. در این پایان‌نامه برای استفاده از شبکه عصبی از داده‌های واقعی بار و اطلاعات آب و هوایی شهرستان مشهد، که از شرکت توزیع و اداره کل هواشناسی شهرستان مشهد دریافت شده بود، جهت پیش‌بینی بار ۲۴ ساعت آینده استفاده شده است.

كلمات کلیدی:

پیش‌بینی بار کوتاه مدت ، شبکه‌های عصبی مصنوعی، پس‌انتشار خطای

فهرست مطالب

صفحه	عنوان
	فصل ۱ مقدمه
۱	۱ پیش‌بینی بار کوتاه مدت و مروری بر کارهای انجام شده
۶	۲ عوامل موثر بر پیش‌بینی بار
۷	۱-۲ عوامل آب و هوایی
۸	۱-۱-۲ عوامل زمانی
۱۰	۲-۱-۲ عوامل اقتصادی
۱۱	۳-۱-۲ عوامل تصادفی
۱۱	۴-۱-۲ روش‌های پیش‌بینی بار از دیدگاه زمانی
۱۲	۲-۲ پیش‌بینی بسیار کوتاه مدت
۱۳	۱-۲-۲ پیش‌بینی کوتاه مدت
۱۳	۲-۲-۲ پیش‌بینی میان مدت
۱۴	۳-۲-۲ پیش‌بینی بلند مدت
۱۴	۴-۲-۲ تاریخچه و روش‌های پیش‌بینی کوتاه مدت بار
۱۵	۳-۲ روش‌های رگرسیون
۱۶	۱-۳-۲ سری‌های زمانی
۱۶	۲-۳-۲ شبکه‌های عصبی
۱۷	۳-۳-۲ رویکرد روز مشابه
۱۹	۴-۳-۲ سیستم‌های خبره
۱۹	۵-۳-۲ منطق فازی
۲۰	۶-۳-۲ تبدیل موجک
۲۱	۷-۳-۲ الگوریتم‌های تکاملی
۲۱	۸-۳-۲ الزامات پردازش پیش‌بینی بار کوتاه مدت
۲۲	۴-۲ دقت زیاد
۲۲	۱-۴-۲ سرعت بالا
۲۳	۲-۴-۲ کشف خودکار اطلاعات غلط
۲۳	۳-۴-۲

۲۳.....	کاربری آسان.....	۴-۴-۲
۲۴.....	دسترسی اتوماتیک به اطلاعات.....	۵-۴-۲
۲۴.....	تولید اتوماتیک نتایج حاصل از پیش‌بینی	۶-۴-۲
۲۴.....	قابلیت انتقال	۷-۴-۲
۲۵.....	مشکلات پیش‌بینی بار کوتاه مدت	۵-۲
۲۵.....	رابطه ورودی و خروجی	۱-۵-۲
۲۶.....	تعمیم تجربه کارشناسان	۲-۵-۲
۲۶.....	پیش‌بینی برای روزهای خاص	۳-۵-۲
۲۶.....	اطلاعات ناقص و کم دقت شرایط آب و هوایی	۴-۵-۲
۲۷.....	قابلیت تولید کمتر ناشی از فرا پوشی	۵-۵-۲
۲۸.....	فصل ۳ شبکه‌های عصبی مصنوعی	۱
۲۹.....	مقدمه	۱-۳
۳۱.....	تاریخچه شبکه‌های عصبی	۲-۳
۳۴.....	کاربرد شبکه‌های عصبی مصنوعی	۳-۳
۳۵.....	۱ تشخیص الگو	۱-۳-۳
۳۵.....	۲ تقریب تابع	۲-۳-۳
۳۵.....	۳ شناسایی ساختار	۳-۳-۳
۳۵.....	رونده استفاده از شبکه‌های عصبی مصنوعی	۴-۳
۳۵.....	۱ مرحله آموزش	۱-۴-۳
۳۶.....	۱-۱-۴-۳ آموزش نظارتی (با معلم).....	۱-۱-۴-۳
۳۶.....	۲-۱-۴-۳ آموزش نظارت نشده (بدون معلم)	۲-۱-۴-۳
۳۷.....	۳-۱-۴-۳ آموزش تقویت شده	۳-۱-۴-۳
۳۷.....	۴-۱-۴-۳ یادگیری روی خط و خارج خط	۴-۱-۴-۳
۳۷.....	۲-۴-۳ الگوهای ورودی و آموزش ورودی‌ها	۲-۴-۳
۳۸.....	۱-۲-۴-۳ تقسیم الگوهای آموزشی	۱-۲-۴-۳
۳۸.....	۲-۲-۴-۳ ترتیب ارائه الگوها	۲-۲-۴-۳
۳۹.....	۳-۲-۴-۳ توقف یادگیری	۳-۲-۴-۳
۳۹.....	۲-۴-۳ رویه‌های بهینه‌سازی گرادیان	۲-۴-۳

۴۱.....	مرحله بازخورد.....	۴-۴-۳
۴۱.....	توابع فعالیت (تبديل).....	۵-۳
۴۱.....	تابع همانی (خطی).....	۱-۵-۳
۴۲.....	تابع پلهای دودویی (با آستانه θ).....	۲-۵-۳
۴۲.....	تابع سیگموید دودویی (سیگموید لجستیک).....	۳-۵-۳
۴۳.....	تابع سیگموید دوقطبی.....	۴-۵-۳
۴۴.....	ساختار شبکه عصبی مصنوعی.....	۶-۳
۴۶.....	شبکه های پیشخورد تک لایه.....	۱-۶-۳
۴۶.....	شبکه های پیشخورد چند لایه.....	۲-۶-۳
۴۷.....	شبکه های برگشتی.....	۳-۶-۳
۴۷.....	ساختارهای مشبك.....	۴-۶-۳
۴۸.....	شبکه عصبی پسانترال.....	۷-۳
۴۸.....	شبکه پسانترال استاندارد.....	۱-۷-۳
۴۹.....	۱- ساختار.....	۱-۱-۷-۳
۵۰.....	۲- الگوریتم پسانترال.....	۲-۱-۷-۳
۵۱.....	۳- فهرست علائم و نامها.....	۳-۱-۷-۳
۵۲.....	۴- تابع فعال سازی.....	۴-۱-۷-۳
۵۲.....	۵- الگوریتم آموزش.....	۵-۱-۷-۳
۵۵.....	۶- انتخاب وزن ها و بایاس های اولیه.....	۶-۱-۷-۳
۵۶.....	۷- مدت زمان آموزش شبکه.....	۷-۱-۷-۳
۵۷.....	فصل ۴ پیش‌بینی کوتاه مدت بار با در نظر گرفتن روزهای خاص.....	
۵۸.....	مقدمه	۱-۴
۵۸.....	روش پیشنهادی	۲-۴
۶۰.....	۱- معماری شبکه عصبی مصنوعی برای مدل پیشنهادی	۱-۲-۴
۶۰.....	۱-۱-۲-۴ انتخاب ورودی های شبکه عصبی	
۶۶.....	۲-۱-۲-۴ لایه نهان شبکه عصبی	
۶۶.....	۳-۱-۲-۴ لایه خروجی شبکه عصبی	
۶۷.....	۲-۲-۴ نرمال سازی داده ها	

۶۷.....	۳-۲-۴ ساختار شبکه عصبی
۷۰.....	۴-۲-۴ معیار تفکیک خطاهای
۷۰.....	۵-۲-۴ بررسی و تحلیل نتایج
۸۰.....	فصل ۵ نتیجه‌گیری و پیشنهادات.....
۸۱.....	۱-۵ نتیجه گیری.....
۸۳.....	۲-۵ پیشنهادات.....
۸۴.....	مراجع

فهرست شکل‌ها

صفحه

عنوان

۹.....	شکل ۱-۲: منحنی دمای هوا، شاخص ناراحتی و رطوبت نسبی برای یک روز کامل [۱]
۱۰.....	شکل ۲-۲: منحنی دمای هوا، سرمای باد و سرعت باد برای یک روز کامل [۱]
۳۰.....	شکل ۱-۳: نرون طبیعی [۴۰]
۳۹.....	شکل ۲-۳: حالت‌هایی از گرادیان نزولی در مورد توابع دو بعدی [۴۳]
۴۰.....	شکل ۳-۳ مشکلات ممکن در گرادیان نزولی [۴۳]
۴۱.....	شکل ۴-۳: تابع همانی [۴۱]
۴۲.....	شکل ۵-۳: تابع پله‌ای دودویی [۴۱]
۴۳.....	شکل ۶-۳: تابع سیگموید دوقطبی با پارامترهای شبیب $\sigma = 1$ و $\sigma = 3$ [۴۱]
۴۳.....	شکل ۷-۳: تابع سیگموید دوقطبی با شبیب $\sigma = 1$ [۴۱]
۴۴.....	شکل ۸-۳: ساختار کلی یک شبکه عصبی [۴۰]
۴۵.....	شکل ۹-۳: ساختار نرون با ۲ ورودی [۴۲]
۴۶.....	شکل ۱۰-۳: ساختار کلی شبکه پیشخورد تک لایه [۴۰]
۴۷.....	شکل ۱۱-۳: ساختار کلی شبکه پیشخورد چند لایه [۴۰]
۴۷.....	شکل ۱۲-۳: ساختار کلی شبکه برگشتی [۴۴]
۴۸.....	شکل ۱۳-۳: ساختار کلی شبکه‌ها با ساختار مشبك
۴۹.....	شکل ۱۴-۳: ساختار یک شبکه عصبی پساننتشار با یک لایه مخفی [۴۱]
۵۹.....	شکل ۱-۴: بار مصرفی ساعتی در روز سه‌شنبه ۱۰ آبان سال ۱۳۸۸ شهرستان مشهد
۵۹.....	شکل ۲-۴: نمودار بلوکی شبکه ساعتی
۶۱.....	شکل ۳-۴: منحنی مصرف روزهای مختلف هفته
۶۲.....	شکل ۴-۴: میزان بار مصرفی شهرستان مشهد در برخی از شهادتها و عزاداری‌های قمری در سال ۱۳۸۹
۶۲.....	شکل ۵-۴: میزان بار مصرفی شهرستان مشهد در برخی از اعیاد و ولادت‌های قمری در سال ۱۳۸۹
۶۳.....	شکل ۶-۴: میزان بار مصرفی شهرستان مشهد در تعطیلات نوروزی سال ۱۳۸۹
۶۳.....	شکل ۷-۴: میزان بار مصرفی شهرستان مشهد در تعطیلات شمسی سال ۱۳۸۹
۶۴.....	شکل ۸-۴: منحنی میزان بار ساعتی مصرفی در روزهای ۹۰/۰۴/۱۳ و ۹۰/۰۴/۱۴ شهرستان مشهد
۶۵.....	شکل ۹-۴: منحنی میزان بار ساعتی مصرفی روز ۲۰ تیر در چهار سال مختلف شهرستان مشهد

..... ۶۹	شکل ۱۰-۴: تابع انتقال تانژانت سیگموید [۴۵]
..... ۶۹	شکل ۱۱-۴: تابع انتقال خطی [۴۵]
..... ۷۶	شکل ۱۲-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۴ مرداد سال ۱۳۹۰
..... ۷۶	شکل ۱۳-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۶ دی سال ۱۳۹۰
..... ۷۷	شکل ۱۴-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۶ مرداد سال ۱۳۹۰
..... ۷۸	شکل ۱۵-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۳ فروردین سال ۱۳۹۰
..... ۷۸	شکل ۱۶-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۶ آبان سال ۱۳۹۰
..... ۷۹	شکل ۱۷-۴: میزان بار واقعی و بار پیش‌بینی شده در ۴ بهمن سال ۱۳۹۰
..... ۷۹	شکل ۱۸-۴: میزان بار واقعی و بار پیش‌بینی شده در ۱۵ آبان سال ۱۳۹۰

فهرست جداول

صفحه	عنوان
۷۱	جدول ۱-۴ میزان درصد خطای مطلق و میانگین درصد خطای مطلق در مرداد ماه سال ۱۳۹۰
۷۳	جدول ۲-۴ میزان درصد خطای مطلق و میانگین درصد خطای مطلق در بهمن ماه سال ۱۳۹۰
۷۵	جدول ۳-۴ میانگین درصد خطای مطلق تعطیلات قمری

فصل اول

مقدمه

کارکرد مطمئن و اقتصادی یک شبکه قدرت، بدون آگاهی نسبی از میزان بار مصرفی در آینده امکان پذیر نمی‌باشد. لذا اولین اقدام برای بهره‌وری و اعمال مدیریت مناسب در یک سیستم، پیش‌بینی بار در آینده خواهد بود که این پیش‌بینی هرچه دقیق‌تر باشد کارکرد شبکه رضایت‌بخشتر و مدیریت بر شبکه دقیق‌تر و مطلوب‌تر خواهد شد.

بار کل یک شبکه قدرت به عنوان یک بار مرکب واحد اما گستردگی باشد که بعلت رفتار مصرف کنندگان مختلف در طی ساعات شبانه‌روز دارای تغییرات نسبتاً ثابت دوره‌ای می‌باشد. بدین صورت که مقدار و شکل تغییرات آن در طی روزهای متوالی هفته، بطور تقریباً مشابهی تکرار می‌گردد. تغییرات بار شبکه نسبت به زمان را می‌توان در دوره‌های مختلف زمانی از جمله بلند مدت، میان مدت، کوتاه مدت و بسیار کوتاه مدت بررسی نمود.

به طور کلی پیش‌بینی کوتاه مدت بار در سیستم قدرت دارای چندین کاربرد است. اولین کاربرد مربوط به زمان‌بندی تولید است که مهمترین هدف پیش‌بینی کوتاه مدت بار است. در سیستم‌های حرارتی از پیش‌بینی، برای محاسبه زمانهای روشن و خاموش بودن هر واحد در برنامه‌ریزی مشارکت واحدها استفاده می‌شود. دومین کاربرد پیش‌بینی بار قابلیت اطمینان سیستم قدرت است که می‌تواند منجر به عملکرد مطمئن‌تر سیستم شود. مورد کاربرد دیگر ذخیره تولید سیستم می‌باشد که ذخیره تولید توان باید بتواند بر کمبودهای ناشی از افزایش ناگهانی بار و خرابی واحدهای تولید فائق آید. میزان مناسب ذخیره را می‌توان بر اساس پیش‌بینی بار تعیین نمود. مورد کاربرد بعدی اطلاع رسانی به سیستم توزیع بار است. سیستم توزیع بار برای بهره‌برداری اقتصادی‌تر از سیستم، نیازمند به اطلاعات زمان واقعی بار در دوره‌های بسیار کوتاه مدت است و آخرین کاربرد آن بهره‌برداری بازار است. بنابراین مهمترین دلیل برای پیش‌بینی بار این است که بتوان بین تولید برق و تقاضای مصرف آن هماهنگی لازم را برقرار نمود. در این صورت اگر میزان بار پیش‌بینی شده کمتر از بار مصرفی باشد،

ضریب اطمینان و در نتیجه کیفیت خدمات کاهش یافته و از سوی دیگر اگر بار پیش‌بینی شده بیش از مقدار مورد نیاز باشد باعث هدر رفتن سرمایه و زیان مالی می‌گردد.

بدین منظور جهت افزایش دقت پیش‌بینی، روش‌های مختلفی چون روش‌های خطی، رگرسیون آماری و فضای حالت پیشنهاد شده است، اما از آنجا که ارتباط بین بار و عوامل موثر بر آن بسیار پیچیده و اغلب غیرخطی است، باعث شده که روش‌های سنتی نظیر روش‌های خطی، سری‌های زمانی و آنالیز رگرسیون نتوانند بخوبی این وابستگی را مدل نموده و علاوه بر آن روش‌های گفته شده، متکی بر مدل‌های ریاضی و پارامتری هستند که شامل چندین مرحله از قبیل مدل‌سازی، شناسایی و تخمین پارامترهای مدل و تأیید صحت آنها می‌باشند که پس از انتخاب مدل مناسب، پارامترهای آن با استی توانایی تطبیق با تغییر شرایط را داشته باشند. به همین دلیل تحقق چنین الگوریتمهایی زمانبر، خسته کننده و پیچیده بوده که اغلب نیازمند تعداد پارامترهای زیاد و حجم حافظه زیادتری می‌باشند. در تحقیقات جدید سعی شده که مشکلات فوق با بکارگیری الگوریتمهای هوشمند همانند سیستم‌های خبره، سیستم‌های فازی و شبکه‌های عصبی مصنوعی، و ترکیبی از آنها مرتفع گردد. ویژگی اصلی شبکه‌های عصبی، قابلیت بالای یادگیری ارتباط بین ورودی‌ها و خروجی‌ها بوده که انجام آن در روش‌های الگوریتمی قدیمی بسیار مشکل و حتی غیر ممکن می‌باشد. بر این اساس از شبکه‌های عصبی به عنوان یک ابزار اساسی در این پایان‌نامه استفاده می‌شود. شبکه عصبی مورد استفاده در این تحقیق، شبکه پیش‌خور با الگوریتم پس انتشار استفاده شده است. این نوع شبکه عصبی توانایی نسبتاً بالایی در حل مسائل تخمین تابع دارند و از آنجا که پیش‌بینی بار نمونه‌ای از مسائل کلی تخمین توابع می‌باشد، در اغلب مقالات از این شبکه عصبی به عنوان بهترین نمونه جهت پیش‌بینی کوتاه مدت بار استفاده می‌شود. تقریباً در بخش عمده‌ای از کارهای انجام شده در زمینه پیش‌بینی بار کوتاه مدت، تخمین بار روزهای عادی با دقت بالایی صورت گرفته است. مشکل عمده در اکثر مقالات پیش‌بینی بار روزهای خاص نظیر مناسبات‌ها و تعطیلات قمری می‌باشد. بررسی‌ها نشان می‌دهد که پیش‌بینی بار

روزهای خاص مانند تاسوعا و عاشورا، اعیاد مذهبی و شهادت‌ها کار بسیار مشکلی است، زیرا یک سال قمری ۳۵۵ روز و یک سال شمسی ۳۶۵ روز می‌باشد و یک روز خاص از ماه قمری در سالهای پیاپی شمسی جابجا می‌شود. این جابجایی باعث می‌شود که اطلاعات نیاز مصرف سالیان گذشته برای سال جاری اعتبار چندانی نداشته باشد. هدف از این پایان‌نامه بهبود پیش‌بینی بار چنین روزهایی می‌باشد و لازمه این امر شناخت و درک رفتار مصرف بار در این روزها است.

از طرفی پیش‌بینی بار کوتاه مدت یک سری الزامات خاص خودش را دارد. یکی از این الزامات محدودیت زمانی انجام پیش‌بینی است. معمولاً محدودیت زمانی پیش‌بینی بار برای ۲۴ ساعت آینده چیزی در حدود ۲۰ الی ۳۰ دقیقه است. برای تحقیق این امر در این پایان‌نامه از روش تفکیک استفاده می‌کنیم. در روش تفکیک شبکه به چندین زیر شبکه تقسیم می‌شود. به عنوان مثال به ازای هر روز هفته از یک شبکه عصبی استفاده می‌کنند. روش کاری ما استفاده از ۲۴ شبکه عصبی برای پیش‌بینی بار ۲۴ ساعت آینده به جای استفاده از یک تک شبکه است. با این کار نتایج حاصل از پیش‌بینی بهتر شده و از طرفی وقت کمتری برای رسیدن به جواب صرف می‌شود.

برای دستیابی به اهداف فوق، گزارش این تحقیق در پنج فصل بشرح زیر تدوین می‌شود. در فصل اول تحت عنوان "مقدمه" به بیان کلیات تحقیق شامل تعریف مسئله، بیان ضرورت و اهداف پژوهش پرداخته شده است. در فصل دوم تحت عنوان "پیش‌بینی بار کوتاه مدت و مروری بر کارهای انجام شده" عوامل موثر بر پیش‌بینی بار، تقسیم بندی مسئله پیش‌بینی بار از نظر زمانی و کاربرد هریک از آنها در سیستم قدرت، روش‌ها و کارهای انجام شده در زمینه پیش‌بینی بار کوتاه مدت و همچنین الزامات و مشکلات این پیش‌بینی مورد بررسی قرار گرفته است. در فصل سوم تحت عنوان "شبکه‌های عصبی مصنوعی" مبانی تئوری و محاسباتی شبکه‌های عصبی مصنوعی ارائه خواهد شد و در فصل چهارم تحت عنوان "پیش‌بینی کوتاه مدت بار با در نظر گرفتن روزهای خاص" تجزیه و تحلیل اطلاعات گردآوری شده و نیز نتایج ارائه می‌گردد. در نهایت در فصل پنجم تحت عنوان "نتیجه گیری

و پیشنهادات" جمع‌بندی کلی تحقیق مربوط به بحث و نتیجه گیری و پیشنهادات می‌باشد و در انتهای منابع مورد استفاده درج خواهد شد.

فصل دوم

پیش‌بینی بار کوتاه مدت
و مروری بر کارهای انجام
شده

۱-۲ - عوامل موثر بر پیش‌بینی بار

نخستین گام در تحقق امر پیش‌بینی بار به نحو مناسب، تعیین عواملی است که بر الگوی بار تاثیر دارند. به طور کلی، بار یک سیستم مرکب از تعداد زیادی از واحدهای مصرفی مختلف می‌باشد. بخش عظیمی از الکتریسیته به وسیله فعالیت‌های صنعتی مصرف می‌شود. بخش دیگر در مصارف خانگی از جمله گرمکن‌ها، روشنایی‌ها، وسایل پخت و پز، ماشین لباسشویی و ... مصرف می‌شود. همچنین سرویس‌های زیادی از قبیل روشنایی معابر، خطوط حمل و نقل شهری و ... تقاضای الکتریسیته اجتماعی را عرضه می‌کنند.

به هر حال به واسطه نکته‌ای که از معاملات برق دیده می‌شود، واحدهای صنعتی معمولاً در پیش‌بینی ها به این دلیل که با رویدادهای غیرمنتظره مثل از کار افتادگی ماشین‌ها یا اعتصاب‌ها که موجب اختلالات غیرقابل پیشگویی در میزان بار می‌شود، با تردید مواجه می‌شوند. عواملی که در زندگی خصوصی مردم، میزان مصرف بار را تعیین می‌کنند به سختی قابل تعریف می‌باشند. برای مثال، رویدادهای بزرگ، تعطیلات و حتی برنامه‌های تلویزیون بر بار مصرفی تاثیر دارند. آب و هوا یک فاکتور منحصر بفرد خیلی مهم می‌باشد، که دلیل اصلی آن وسایل گرمایشی و سرمایشی الکتریکی، منازل و ادارات می‌باشند که در هنگام افت یا افزایش درجه حرارت هوا کاربرد دارند. عوامل موثر بر پیش‌بینی بار را می‌توان به چهار دسته زیر تقسیم بندی کرد:

الف: عوامل آب و هوایی

ب: عوامل زمانی

ج: عوامل اقتصادی

د: عوامل تصادفی

در ادامه اثرات این عوامل معرفی شده برای ارائه یک درک اساسی از ویژگی‌های بار، توضیح داده شده است.

۱-۱-۲ عوامل آب و هوایی

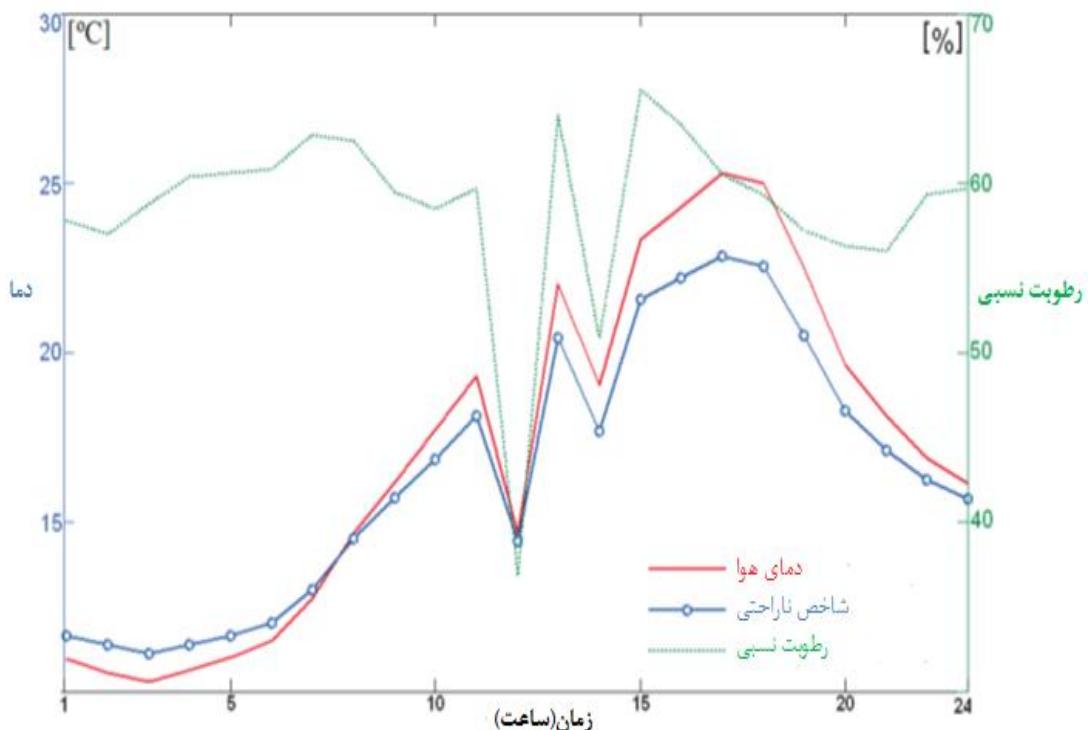
عوامل آب و هوایی شامل دما، رطوبت، میزان بارش، سرعت باد، پوشش ابر (میزان روشنایی در طول روز)، شدت نور و ... می‌باشند. تغییر شرایط آب و هوایی باعث تغییر در احساس راحتی مصرف-کنندگان و به نوبه خود استفاده از برخی سیستم‌های گرمایشی و سرمایشی و تهویه‌ی هوای مطبوع را به دنبال دارد، که این امر اثرات قابل توجهی در الگوی مصرف بار داشته و اثرات کوتاه مدت را نشان می‌دهد. مصرف بار دستگاه‌های آبیاری کشاورزی نیز به دلیل نیاز برای آبیاری گیاهان زیر کشت شدیداً احساس به شرایط آب و هوایی است.

به طور معمول درجه حرارت روزانه مهم‌ترین متغیر آب و هوایی در روند محاسبه مصرف روزانه بار به شمار می‌رود، به این خاطر است که همواره درجه حرارت به عنوان یک متغیر مستقل در پیش‌بینی کوتاه مدت بار به کار گرفته می‌شود. درجه حرارت روزهای گذشته نیز بر مصرف بار تاثیر می‌گذارد. برای مثال، به طور مداوم بالا رفتن درجه حرارت در روزهای گذشته ممکن است یک حس گرمتر شدن در بین مصرف‌کنندگان ایجاد نموده و به همراه آن یک پیک تقاضای جدید به وجود آید. رطوبت نیز یک عامل بسیار مهم به شمار می‌آید، زیرا تاثیر آن بر روی احساس آسایش انسان تا حد زیادی بالاست. میزان دمای احساسی مردم در محیطی با درجه حرارت 35°C درجه سانتی‌گراد و رطوبت نسبی 70% درصد بالاتر از محیطی با درجه حرارت 37°C درجه سانتی‌گراد و رطوبت نسبی 50% درصد است. به همین دلیل گاهی از اوقات از شاخص ناراحتی^۱ به عنوان یک عامل موثر در پیش‌بینی بار استفاده می‌شود. این شاخص به صورت زیر تعریف می‌شود [۱]:

$$DI = T_A - 0 / 55 \left(1 - \frac{RH}{100} \right) \cdot (T_A - 14) \quad (1-2)$$

^۱ Discomfort Index (DI)

که در آن DI شاخص ناراحتی بر حسب ($^{\circ}\text{C}$), T_A دمای هوا بر حسب ($^{\circ}\text{C}$) و R_H رطوبت نسبی بر حسب (%) می‌باشند. در شکل (۱-۲) شاخص ناراحتی و تغییرات دما در طول یک روز نشان داده است. همان‌طور که مشاهده می‌شود تغییرات شاخص ناراحتی بسیار شبیه به تغییرات دما در طول روز است. شاخص ناراحتی اهمیت تغییرات دمای هوا و رطوبت نسبی را نشان می‌دهد [۱].



شکل ۲-۱- منحنی دمای هوا، شاخص ناراحتی و رطوبت نسبی برای یک روز کامل [۱]

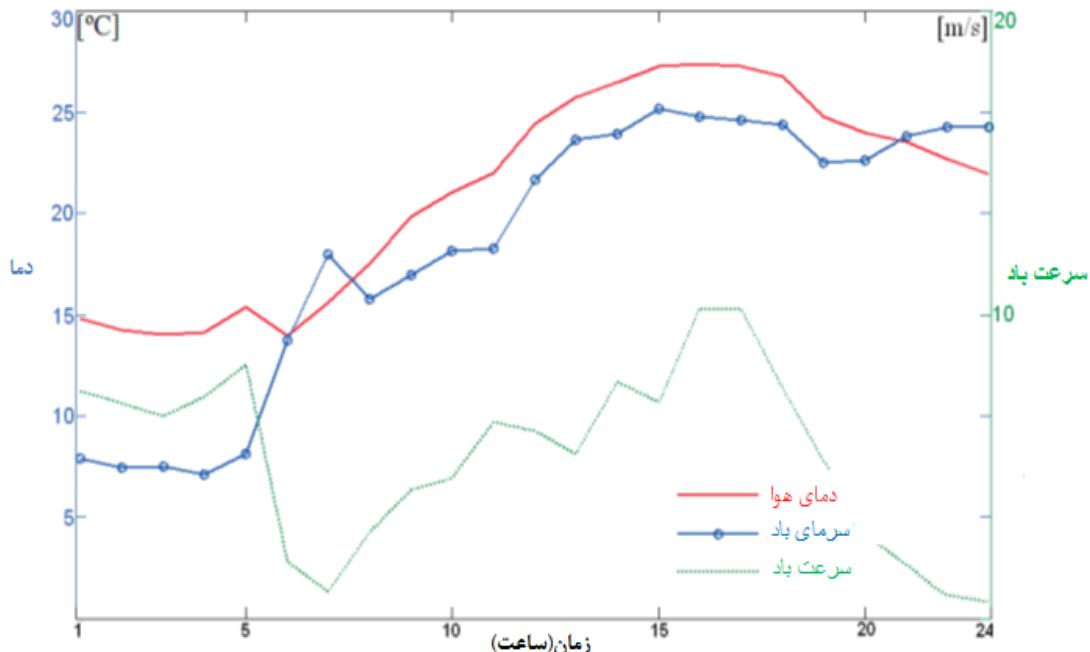
همچنین با افزایش سرعت باد به خصوص در دماهای پایین، میزان دمای احساسی مردم بسیار سردتر از میزان درجه حرارت واقعی است. به همین دلیل، شاخص سرمای باد^۱ به عنوان عاملی که احساس سردی را اندازه گیری می کند، در برخی از مقالات یکی از متغیرهای آب و هوایی مناسب برای ورودی پیش‌بینی کوتاه مدت بار به شمار می‌رود. این شاخص که تعیین کننده دمای واقعی تجربه شده در اثر وزش باد توسط انسان می‌باشد، به صورت زیر تعریف می‌شود [۲]:

^۱ Wind Chill

$$WC = 33 + \frac{\left(10\sqrt{W_S} + 10/45 - W_S\right)(T_A - 33)}{22} \quad (2-2)$$

که در آن WC سرمای باد بر حسب ($^{\circ}C$)، T_A دمای هوا بر حسب ($^{\circ}C$) و W_s سرعت باد بر حسب $\left(m/s\right)$ می‌باشد.

منحنی‌های سرمای باد، دمای هوا و سرعت باد در طول یک روز در شکل (۲-۲) نشان داده شده است [۱]. همان‌طور که مشاهده می‌شود تغییرات شاخص سرمای باد متناسب با تغییر دمای هوا است. از سوی دیگر نیز اثرات تغییرات سرعت باد نیز بر این شاخص کاملاً مشهود است.



شکل ۲-۲- منحنی دمای هوا، سرمای باد و سرعت باد برای یک روز کامل [۱]

۲-۱-۲ عوامل زمانی

عوامل زمانی در مدلسازی مصرف بسیار موثر بوده و نقش تعیین کننده‌ای را در ارزیابی الگوهای مصرف دارد. این عوامل در برگیرنده آثار فصلی، هفتگی و روزانه هستند. آثار فصلی شامل ساعت روشنایی روز در هر فصل است که باعث تغییر برنامه ساعت کار مراکز صنعتی و تجاری

می‌شود. از دیگر رویدادهایی که به‌طور فصلی رخ می‌دهند می‌توان از شروع به کار مراکز آموزشی و تعطیلات سالیانه نام برد که باعث ایجاد دوره‌های فصلی در منحنی بار می‌شوند. دوره‌های هفتگی و روزانه در منحنی بار از عواملی چون فعالیت‌های اقتصادی و اجتماعی در جامعه تاثیر می‌پذیرند. بارهای صنعتی در ایام هفته، مقدار بیشتری نسبت به آخر هفته دارند. تعطیلات آخر هفته در تناوب هفتگی بار موثر بوده و وجود روزهای تعطیل بین هفته و همچنین تعطیلات متوالی در طول سال نیز اثرات خاص خود را دارند، زیرا میزان مصرف بار در طول تعطیلات، کمتر از مقدار معمول خواهد بود، که این موارد از نظر پیش‌بینی بار باعث ایجاد مشکل می‌شوند.

۳-۱-۲ عوامل اقتصادی

محیط اقتصادی که یک سیستم قدرت در آن بهره‌برداری می‌شود، تاثیر قابل ملاحظه‌ای بر روند مصرف بار دارد. در آن دسته از بازارهای برق که قیمت برق، متغیر است و ارتباط پیچیده‌ای را با بار سیستم نشان می‌دهد، ملاحظات اقتصادی را عامل مهمی در پیش‌بینی بار قلمداد می‌کنند. همچنین فاکتورهایی مثل سطح فعالیت‌های صنعتی و کشاورزی، میزان رشد جمعیت و رشد اقتصادی منطقه بر روی الگوی مصرف بار تاثیر گذاشته و باید توسط برنامه‌ریزان و طراحان شبکه مورد توجه قرار گیرد. این‌گونه عوامل معمولاً در مقیاس زمانی بسیار طولانی‌تر از یک هفته اثر خود را آشکار می‌کنند و در نتیجه این متغیرها در مدل‌های پیش‌بینی کوتاه مدت به‌طور صریح وارد نمی‌گردند.

۴-۱-۲ عوامل تصادفی

کلیه عواملی که در روند مصرف بار موثر بوده و در هیچ یک از گروههای فوق قرار نمی‌گیرند، در این دسته منظور خواهند شد. هر سیستم قدرت به‌طور مداوم در معرض نوسانات تصادفی بار بوده و این حالت ناشی از ترکیب پیچیده سیستم از بارهای کوچک و بزرگ می‌باشد که هر کدام الگوی خاص متفاوتی را ارائه می‌دهند. راه اندازی و خاموش کردن بارهای بزرگ مانند صنایع فولاد و ... ممکن است، نوسان‌های شدید و غیر قابل پیش‌بینی را در منحنی بار ناحیه‌ای و در نتیجه بار کل شبکه

ایجاد نمایند. راه اندازی و زمان خاموش شدن این کاربران کاملاً تصادفی است. مسئله اساسی در اینجا مشخص نبودن ساعت دقیق و منظم کارکرد این قبیل از صنایع می‌باشد. عوامل دیگری مانند سیل، طوفان، زلزله، رعد و برق، قطع خطوط انتقال، رویدادهای اجتماعی، تعطیلات غیرمنتظره، برنامه‌های تلویزیونی، مسابقات فوتبال، اعتصابات و . . . که زمان و میزان تاثیرشان بر روی منحنی بار مشخص نیست، به عنوان عوامل تصادفی شناخته می‌شوند.

چهار عامل ذکر شده، در مجموع الگوی مصرف بار را تعیین می‌کنند و هنگامی که بتوان اثر یک به یک آنها را در منحنی مصرف بار شناسایی نمود، می‌توان یک پیش‌بینی نسبتاً دقیق از بار بدست آورد. اما با این همه، هیچگاه نمی‌توان مقدار بار را به‌طور کاملاً دقیق پیش‌بینی نمود و همواره درصدی از خطای وجود خواهد داشت. وارد کردن متغیرهای فوق در مدل ریاضی بار می‌تواند خطای حاصل از پیش‌بینی را کاهش دهد. مسلماً هر چه پارامترها و متغیرهای بیشتری برای مدل در نظر گرفته شود، انتظار نتایج بهتری می‌رود ولی در مقابل، میزان محاسبات و زمان انجام آن افزایش می‌یابد. بنابراین همواره بین این دو وضعیت، مناسب‌ترین حالت باید انتخاب شود.

۲-۲- روش‌های پیش‌بینی بار از دیدگاه زمانی

روش‌های پیش‌بینی بار از دیدگاه زمانی به چهار گروه عمده تقسیم بندی می‌گردند. این تقسیم‌بندی شامل موارد زیر می‌باشد:

الف: پیش‌بینی بسیار کوتاه مدت^۱

ب: پیش‌بینی کوتاه مدت^۲

^۱ Very Short Term Load Forecasting (VSTLF)

^۲ Short Term Load Forecasting (STLF)

ج: پیش‌بینی میان مدت^۱

د: پیش‌بینی بلند مدت^۲

در ادامه این موارد شرح داده می‌شوند.

۱-۲-۲- پیش‌بینی بسیار کوتاه مدت

این پیش‌بینی برای فواصل زمانی پنج دقیقه تا یک ساعت صورت می‌گیرد. کاربرد این قبیل از پیش‌بینی‌ها در سیستم قدرت شامل موارد زیر می‌باشد [۳-۴]:

- کنترل تولید اتوماتیک^۳

- تعیین ذخیره گردان مورد نیاز توسط اپراتور سیستم مستقل

- بهره برداری اقتصادی

- رعایت محدودیت‌های شبکه

۱-۲-۲-۲- پیش‌بینی کوتاه مدت

این پیش‌بینی معمولاً برای فواصل زمانی یک ساعت تا یک هفته انجام می‌شود. این پیش‌بینی نقش مهمی در عملکرد و برنامه‌ریزی سیستم‌های قدرت دارد که شامل موارد زیر می‌باشد [۵-۶]:

- برنامه‌ریزی ورود و خروج واحدها^۴

- برنامه‌ریزی تعمیرات و نگهداری

- توزیع اقتصادی^۵

- تخصیص ذخیره مطمئن

- تعیین قیمت توسط اپراتور بازار برای شرکت‌کنندگان در مناقصه بازار برق

^۱ Mid Term Load Forecasting (MTLF)

^۲ Long Term Load Forecasting (LTLF)

^۳ Automatic Generation Control (AGC)

^۴ Unit Commitment

^۵ Economic Dispatch

- تجزیه و تحلیل وقوع حوداث احتمالی و مطالعات اتصال کوتاه و پایداری شبکه
- استفاده مطلوب و اقتصادی از سوخت نیروگاهها و رعایت محدودیت‌های ناشی از کمبود سوخت

-۳-۲-۲ پیش‌بینی میان مدت مدت

این پیش‌بینی معمولاً برای فواصل زمانی یک هفته تا چند سال انجام می‌شود.

این پیش‌بینی نقش مهمی در برنامه‌ریزی، بهره‌بردای و طراحی سیستم‌های قدرت دارد که شامل موارد زیر می‌باشد [۷-۸]:

- برنامه‌ریزی منابع سوخت و منابع انرژی محدود

- تولید و بهره‌بردای بهینه

- خرید سوخت

- برنامه‌ریزی تعمیرات و نگهداری

- هماهنگی واحدهای آبی- حرارتی

- ارزیابی قابلیت اطمینان

-۴-۲-۲ پیش‌بینی بلند مدت

این پیش‌بینی معمولاً برای فواصل زمانی چند سال تا چند دهه انجام می‌شود. این پیش‌بینی نقش مهمی در عملیات طراحی و برنامه‌ریزی اقتصادی سیستم‌های قدرت در آینده را دارد، که شامل موارد زیر می‌باشد [۸-۹]:

- توسعه تاسیسات تولید، انتقال و توزیع

- بررسی عوامل اقتصادی و تعیین بودجه‌بندی ناحیه‌ای

- مطالعه طرح‌های جامع انرژی

۳-۲- تاریخچه و روش‌های پیش‌بینی کوتاه مدت بار

نتایج حاصل از تحقیقات بر پیش‌بینی کوتاه مدت بار بطور کلی به دو بخش روش‌های آماری و تکنیک‌های هوش مصنوعی تقسیم می‌شود [۱۰]. در روش‌های آماری معادلات قادرند رابطه بین بار و فاکتورهای مربوطه را پس از آموزش و بکارگیری اطلاعات پیشین بدست آورند، ولی در تکنیک‌های هوش مصنوعی سعی می‌شود از انسان تقلید شده و روش تفکر و پاسخ یابی با استناد به تجربیات گذشته، پیش‌بینی بار آینده صورت گیرد.

روش‌های آماری شامل رگرسیون خطی چندگانه [۱۱]، سری‌های زمانی تصادفی [۱۲]، هموارسازی نمائی عمومی [۱۳]، فضای حالت [۱۴] و غیره می‌باشند. معمولاً روش‌های آماری قادرند منحنی بار روزهای معمول را به خوبی پیش‌بینی کنند، ولی در این روش‌ها عدم توانایی آنالیز بار روزهای تعطیل و روزهای خاص به عنوان یک ضعف شناخته شده است که این ضعف دلیلی جز عدم قابلیت انعطاف پذیری روش‌های آماری در برابر عوامل غیرخطی از قبیل شرایط آب و هوایی، تغییرات دوره‌ای روزانه، هفتگی، فصلی و عوامل اتفاقی که دارای روابط پیچیده غیرخطی با بار هستند، نمی‌تواند داشته باشد. سیستم خبره [۱۵]، شبکه عصبی مصنوعی [۱۶]، منطق فازی [۱۷]، و الگوریتم تکاملی در طبقه‌بندی هوش محاسباتی قرار می‌گیرند.

سیستم‌های خبره با دریافت اطلاعات مورد نیاز از اپراتور تلاش می‌کنند اطلاعات را به فرم "اگر...آنگاه" درآورند، ولی مشکل آنجا پدیدار می‌شوند که متخصصان گاهی نمی‌توانند برخی اطلاعات شهودی را به آسانی بیان کنند. یک شبکه عصبی مصنوعی با ارزیابی ارتباط بر قرار شده بین ورودی‌ها و خروجی آنها، نیازی به تعریف تجربه انسانی ندارد. شبکه عصبی مصنوعی با استفاده از معادلات غیرخطی رابطه بین بار و فاکتورهای مربوطه را به خوبی نشان می‌دهد، ولی در موقع همپوشانی^۱(بیش برازش) و آموزش طولانی مدت دچار مشکل می‌شوند. منطق فازی توسعه یافته سیستم‌های خبره می‌باشد. در

^۱ Over Fitting

این مورد منطق فازی یک ساختار ساده شده بهینه را ارائه می‌دهد که خطاهای مدل و تعداد روابط موجود را به منظور اخذ رفتار غیرخطی بارهای کوتاه مدت، به کمترین حد می‌رساند، اما با این حال برای تولید قواعد فازی مستلزم تجربیات کارشناسان است. الگوریتم‌های تکاملی به منظور بهینه‌سازی معادلات چندگانه بهبود داده شده‌اند که از آنها به عنوان آموزش دهنده شبکه عصبی برای دستیابی به نتایج بهتر استفاده می‌شود. عموماً روش‌های هوش مصنوعی، در یافتن ارتباط میان بار و فاکتورهای مربوطه، مخصوصاً برای پیش‌بینی بار روزهای خاص انعطاف‌پذیر می‌باشند.

تعدادی از روش‌های اصلی پیش‌بینی بار کوتاه مدت به صورت زیر معرفی می‌گردند.

۱-۳-۲ - روش‌های رگرسیون^۱

رگرسیون یکی از پر کاربردترین تکنیک‌های آماری می‌باشد. به منظور پیش‌بینی بار، روش‌های رگرسیون معمولاً ارتباط میان محاسبات بار و سایر فاکتورها نظیر وضع هوا، نوع روز و نوع مشتری را مدل می‌کنند. این مدل‌ها تاثیرات قطعی مانند تعطیلات، تاثیرات اتفاقی مانند بارهای میانگین و تاثیر عوامل مستقل مانند وضع هوا را با هم یکی می‌کنند. مراجع [۱۸-۱۹]، سایر ابزارهای مدل رگرسیون اعمال شونده برای پیش‌بینی بار را توضیع داده‌اند.

۲-۳-۲ - سری‌های زمانی^۲

سری‌های زمانی در زمینه‌هایی شامل، اقتصاد، پردازش سیگنال دیجیتال، از جمله پیش‌بینی بار کوتاه مدت به کار گرفته شده‌اند. از مهمترین مدل‌هایی که از آنها برای پیش‌بینی بار استفاده می‌شود می‌توان به مدل اتورگرسیو میانگین متحرک^۳ (ARMA)، اتورگرسیو تجمعی میانگین

^۱ Regression

^۲ Time Series

^۳ Autoregressive Moving Average

متحرک^۱ (ARIMA) و اتورگرسیو تجمعی میانگین متحرک با متغیرهای خارجی^۲ (ARIMAX) اشاره کرد.

مدل‌های ARMA معمولاً در پردازش استاتیک بکار می‌روند، در حالی که ARIMA تعمیم یافته ARMA بوده که به پردازش‌های غیر استاتیک می‌پردازد. در مدل‌های ARMA و ARIMA، بار و زمان بعنوان تنها پارامترهای ورودی در نظر گرفته می‌شوند. از آنجا که بار کلاً به وضع هوا و زمان روز بستگی دارد، از مدل ARIMAX بیشتر از سایر روش‌های سری زمانی به عنوان ابزاری برای پیش‌بینی بار استفاده شده است.

آقایان فن و مکدونالد کاربرد ARIMAX را در امر پیش‌بینی بار توضیح داده‌اند [۲۰]. آقای یانگ و همکارانش در یک پیش‌بینی بار یک برنامه‌ریزی تکاملی را برای شناسایی پارامترهای ARIMAX به مدت یک روز تا یک هفته، ساعت به ساعت پیش بردند. برنامه ریزی تکاملی روشی است برای شبیه‌سازی سیر تکاملی و یک الگوریتم بهینه‌سازی تصادفی را بنا می‌کند [۲۱]. آقایان یانگ و هوانگ نوعی اتورگرسیو فازی تجمعی با میانگین متحرک با متغیرهای خارجی (FARMAX) را برای یک روز بصورت پیش‌بینی بار ساعتی ارائه داده‌اند [۲۲].

شبکه‌های عصبی -۳-۳-۲

بکارگیری شبکه‌های عصبی مصنوعی از ۱۹۹۰ بطور گسترده در زمینه پیش‌بینی بار بکار گرفته شده است [۲۳]. شبکه‌های عصبی مدارهای غیرخطی هستند که توانایی انجام برازش منحنی را دارا می‌باشند. خروجی‌های یک شبکه عصبی تعدادی توابع ریاضی خطی یا غیرخطی از ورودی‌ها می‌باشند. ورودی‌ها به نوبه خود می‌توانند خروجی المان‌های دیگر شبکه باشند. عملاً المان‌های شبکه در تعداد کمتری لایه‌های مرتبط تقسیم‌بندی شده‌اند، که ورودی را به خروجی ارتباط می‌دهند. گاهی اوقات مسیرهای پس‌خور هم استفاده می‌شود. در بکارگیری شبکه عصبی به منظور پیش‌بینی بار، غالباً یکی

^۱ Autoregressive Integrated Moving Average

^۲ Autoregressive Integrated Moving Average with Exogenous Variables

از ساختارها (مثلا هاپفیلد، پس انتشار، ماشین بولتزمن)، تعداد و ارتباط لایه‌ها و المان‌ها، کاربرد مسیرهای تک‌سو و دوسو و فرمت عددی (مثلا باینری یا پیوسته) توسط ورودی‌ها و خروجی‌ها انتخاب می‌شوند [۲۲].

معروف‌ترین ساختار شبکه عصبی برای بکارگیری در پیش‌بینی بار، پس انتشار می‌باشد. این شبکه توابع پیوسته مقداردهی شده و آموزش با نظارت را بکار می‌گیرد. تحت آموزش با نظارت وزن‌های عددی واقعی با انطباق دادن اطلاعات پیشین (مانند زمان و وضع هوا) با خروجی‌های مطلوب (مانند اطلاعات بارها) در یک پیش‌دوره آموزشی پیش‌بینی و به متغیرهای ورودی نسبت داده می‌شوند.

آقای باکیرتزیس و همکارانش مدل پیش‌بینی بار کوتاه مدتی بر پایه شبکه عصبی مصنوعی برای مرکز کنترل انرژی تعاونی توان جمهوری یونان ارائه داده‌اند. در این کار آنها یک شبکه عصبی متشکل از سه لایه پیشخور کاملاً مرتبط و یک الگوریتم پس انتشار برای آموزش بکارگرفته‌اند. متغیرهای ورودی شامل اطلاعات بار پیشین، دما و روز هفته می‌شوند [۲۴]. همین‌طور توسط پاپالکسوسپولوس و همکارانش، شبکه‌ای پیشخور چند لایه را برای پیش‌بینی بار کوتاه مدت سیستم، توسعه و بکارگرفتند. در مدل معرفی شده سه نوع متغیر به عنوان ورودی‌های شبکه عصبی معرفی شده‌اند. ورودی‌های استفاده شده مربوط به فصل‌ها، وضع هوا و بارهای پیشین می‌بودند [۲۵]. آقای خوتانزد و همکارانش یک سیستم پیش‌بینی بار تحت عنوان ANNSTLF را ارائه داده‌اند. این سیستم بر پایه استراتژی شبکه عصبی مصنوعی چندگانه بنا شده که تمایلات متفاوت بار را دریافت می‌کند. در این رویکرد آنها یک شبکه عصبی پرسپترون چندلایه با الگوریتم آموزشی پس انتشارخطا را بکار گرفتند. تاثیر دما و رطوبت بر بار در ANNSTLF قابل بررسی می‌باشد. این روش قابلیت پیش‌بینی دمای ساعتهای مختلف روز و میزان رطوبت مربوطه را دارا می‌باشد [۲۶]. بهبود سیستم فوق در مرجع [۲۷] مورد ارزیابی قرار گرفته است. در نسل جدید روش ANNSTLF شامل دو پیش‌بینی توسط شبکه عصبی بوده، که یکی بار پایه و دیگری تغییرات بار را پیش‌بینی می‌کند. پیش‌بینی نهایی با ترکیب تطبیقی بین این پیش‌بینی‌ها صورت می‌پذیرد. تاثیر رطوبت و سرعت باد توسط یک تبدیل خطی از

دما در نظر گرفته می‌شود. آقای چن و همکارانش [۲۸]، یک شبکه سه لایه پیشخور عصبی با یک الگوریتم پس انتشار به عنوان روش آموزش بکار گرفتند. شبکه عصبی مصنوعی پیشنهادی آنها هزینه برق را به عنوان یکی از پارامترهای اساسی بار سیستم منظور می‌کند. بسیاری از تحقیقات منتشره شبکه‌های عصبی مصنوعی را در کنار سایر تکنیک‌های پیش‌بینی نظیر سری‌های زمانی [۲۹]، و منطق فازی [۳۰] بکار برده‌اند.

۴-۳-۲ رویکرد روز مشابه

این رویکرد بر مبنای جستجوی پیشینه اطلاعات موجود روزهای یک سال یا حتی دو تا سه سال با ویژگی‌های مشترک پایه ریزی شده است. ویژگی‌های مشترک شامل وضع هوا، روز هفته و تاریخ می‌گردد. بار روزهای مشابه به عنوان یک پیش‌بینی تلقی می‌شود. بجای بار یک تک روز مشابه، پیش‌بینی قادر است یک ترکیب خطی یا شیوه‌ای شامل رگرسیون باشد که تعداد زیادی از روزهای مشابه را در برگیرد. ضرایب مربوطه می‌توانند برای روزهای مشابه سال‌های پیشین بکار روند [۳۱].

۴-۳-۲ سیستم‌های خبره^۱

پیش‌بینی بر مبنای قانون از قواعدی اتفاقی تبعیت می‌کند تا به دقتی بالا در پیش‌بینی دست یابد. سیستم‌های خبره روش‌های بکار رفته توسط افراد خبره را با نرم افزارهای کامپیوتری تلفیق کرده که قادر است بدون دخالت انسان بصورت خودکار پیش‌بینی کند.

آقای هو و همکارانش سیستم خبره پایه‌ریزی شده علمی را برای پیش‌بینی کوتاه مدت بار سیستم قدرت تایوان معرفی کرده‌اند. دانش اپراتورها و نظارت ساعتی بار سیستم در سراسر ۵ سال گذشته بمنظور ایجاد ۱۱ گونه روز بکار گرفته شده‌اند. پارامترهای جوی نیز در نظر گرفته شده‌اند [۳۲]. رحمان و همکارانش یک تکنیک مستقل از پایگاه برای پیش‌بینی کوتاه مدت بار ارائه داده‌اند. آگاهی و علم به بار و فاکتورهای موثر منجر به استخراج تاثیرات آنها شده و یک قواعد پارامتریک را نتیجه

^۱ Expert Systems

می‌دهد. این سیستم مبتنی بر قواعد پارامتر یک پایگاه داده است که بسته به پایگاه مربوطه متفاوت است. این تکنیک در پایگاه‌های مختلفی در ایالت متحده آمریکا تست شده و خطای پیش‌بینی کمی گزارش شده است. مدل بار، قواعد و پارامترها که در مقاله ارائه شده‌اند بدون استفاده از دانش خاصی در مورد هر نوع پایگاه خاصی طراحی شده‌اند. در صورتی که پایگاه خاصی مد نظر اپراتور باشد نتایج بهتری حاصل می‌شود [۳۳].

۲-۳-۶- منطق فازی^۱

منطق فازی حالت عمومی شده منطق بولی بوده که در طراحی مدارهای دیجیتال به کار می‌روند. ورودی در منطق بولی یکی از این دو حالت ۰ یا ۱ (درست یا غلط) است. در منطق فازی یک ورودی با گسترهای از کمیت‌های خاص مرتبط می‌شود. برای مثال دمای روز در یک لحظه ممکن است کم، متوسط و زیاد باشد. منطق فازی به ما کمک می‌کند که خروجی‌ها را از روی ورودی‌ها نتیجه بگیریم. در میان فواید موجود در بکارگیری منطق فازی عدم نیاز به مدلی ریاضی برای نگاشت ورودی به خروجی و همچنین عدم نیاز به ورودی‌های است. با وجود چنین قواعد عمومی، طراحی سیستم‌های فازی برای پیش‌بینی بار ساده خواهد بود. البته در بسیاری از شرایط یک خروجی واقعی و مطلوب مورد نیاز است. بعد از عملیات پردازش ورودی‌های فازی، عملیات خارج سازی از منطق فازی برای حصول به یک خروجی دقیق نیاز است. مرجع [۳۴] بکارگیری منطق فازی در پیش‌بینی بار را توضیح داده است.

^۱ Fuzzy Logic

۷-۳-۲ تبدیل موجک^۱

یک مدل پژوهشی بار کوتاه مدت از شبکه‌های بر پایه موجک در مرجع [۳۵] بمنظور مدلسازی رفتار دینامیکی بشدت غیرخطی بارهای سیستم و بهبود کارایی شبکه‌های عصبی مصنوعی معمول ارائه شده است. شبکه‌های سه لایه موجک، وزن، و جمع زدن گره‌ها توسط یک الگوریتم محاسبات تکاملی ساخته شده است. در واقع لایه اول گره‌های موجک، سیگنال‌های ورودی را به سیگنال‌های گوناگونی تجزیه کرده که به هر یک وزن متفاوتی در لایه دوم که لایه وزن‌دهی به گره‌ها است، تخصیص می‌دهد. در نهایت در لایه سوم با ترکیب گره‌های جمع زننده مقادیر وزن دهی شده را با سیگنال‌های خروجی مقایسه می‌کند. در ساختار الگوریتم محاسباتی تکمیلی، پارامترهایی که باید در شبکه تنظیم شوند به مجموعه‌ای از بردارهای جمعیت تبدیل می‌شوند. این جمعیت با یک به روش تصادفی ایجاد فرزندان، رقابت افراد، و جهش تشکیل شده است.

در مرجع [۳۵] برای بررسی کارایی استنتاج ارائه شده پیش‌بینی بار در شبکه‌های بر پایه موجک، بار واقعی و اطلاعات جوی برای سیستم قدرت تایوان بکار گرفته شده است. با بکارگیری این اطلاعات به عنوان مرجع برای پیش‌بینی متغیرهای ورودی شبکه‌ها، یک آنالیز استاتیک توابع هم بسته بین بار پیشین و متغیرهای جوی صورت گرفته است. مقایسه‌ای با بکارگیری شبکه‌های عصبی مصنوعی با الگوریتم آموزش پس‌انتشار برای پیش‌بینی بار کوتاه مدت، انجام شده است که نشان می‌دهد، پیش‌بینی بار مبتنی بر شبکه عصبی مصنوعی از سرعت و دقیقت بیشتری در ارائه نتایج برخوردار است.

۸-۳-۲ الگوریتم‌های تکاملی^۲

الگوریتم‌های تکاملی مانند الگوریتم ژنتیک (GA) [۳۶]، بهینه‌سازی ازدحام ذرات (PSO) [۳۷]، سیستم ایمنی مصنوعی (AIS) [۳۸]، بهینه‌سازی کلونی مورچگان (ACO) [۳۹] برای آموزش

^۱ Wavelet

^۲ Evolutionary Algorithms

شبکه‌های عصبی در پیش بینی کوتاه مدت بار استفاده شده است. طبق گفته این مراجع، الگوریتم‌های تکاملی در همگرایی نسبت به الگوریتم پساننتشار عملکرد بهتری دارد.

۴-۲- الزامات پردازش پیش بینی بار کوتاه مدت

تقریبا در مراکز کنترل مدرن تمامی سیستم‌های مدیریت انرژی، یک مجموعه پیش بینی کوتاه مدت بار موجود است. یک سیستم خوب پیش بینی بار کوتاه مدت بار باید الزامات و نیازهایی را برآورده کند. این الزامات به شرح زیر می‌باشند:

الف: دقیق زیاد

ب: سرعت بالا

ج: کشف خودکار اطلاعات غلط

د: کاربری آسان

ه: دسترسی اتوماتیک به اطلاعات

و: تولید خودکار نتایج حاصل از پیش بینی

ز: قابلیت انتقال

در ادامه در مورد هر یک از این الزامات صحبت می‌شود.

۱-۴-۲ - دقیق زیاد

مهم‌ترین نیاز یک پردازش پیش بینی بار کوتاه مدت، دقیق بالای پیش بینی آن است. دقیق خوب اساس توزیع اقتصادی هزینه، قابلیت اطمینان سیستم و بازارهای برق می‌باشد. هدف اصلی در بسیاری از مقالات منتشره پیرامون پیش بینی بار کوتاه مدت و نیز این پایان نامه بالا بردن دقیق پیش بینی تا میزان ممکن می‌باشد.

سرعت بالا -۴-۲

سرعت بالای بکارگیری جدیدترین اطلاعات گذشته و پیش‌بینی جوی، به بالا بردن دقت کمک می‌کند. زمانی که موعد نتایج پیش‌بینی بار شده تعیین شد، با بکارگیری به روزترین اطلاعات پیشین بار و وضع هوا زمان اجرای برنامه پیش‌بینی بار کوتاه مدت طولانی خواهد بود. بنابراین سرعت بالای اجرای برنامه پیش‌بینی بار، نیاز اساسی برنامه پیش‌بینی بار است. برنامه‌هایی که به زمان آموزش زیادی نیاز دارند باید کنار گذاشته شده و تکنیک‌های جدیتر برای کاهش زمان آموزش باید مورد نظر قرار گیرند. معمولاً زمان مورد نیاز پیش‌بینی ۲۴ ساعته حدوداً ۲۰ دقیقه است.

کشف خودکار اطلاعات غلط -۴-۳

در سیستم‌های قدرت مدرن دستگاه‌های اندازه‌گیری در سراسر شبکه نصب شده‌اند و اطلاعات را به مرکز کنترل توسط خطوط ارتباطی انتقال می‌دهند. با توجه به خطاهای موردنی رخ دهنده در ارتباط دهنده‌ها یا اندازه‌گیرها، گاهی اطلاعات واصله به مرکز کنترل غلط است ولی با این حال اطلاعات در پایگاه داده‌ها ذخیره می‌شوند. در حال حاضر سیستم‌های پیش‌بینی بار کوتاه مدت و اپراتورها در ارتباطند تا از دریافت اطلاعات غلط اجتناب کنند. تمایل بر این است که خود سیستم این امر را تحت پوشش قرار داده و نقش اپراتور حذف شود تا قابلیت کشف این گونه اطلاعات غلط بالا رود.

کاربری آسان -۴-۴

استفاده از سیستم پیش‌بینی بار برای کاربر باید آسان، راحت و عملی باشد. کاربر باید به آسانی متوجه شود چه باری پیش‌بینی می‌شود، و این امر توسط جداول و منحنی‌ها پیش‌بینی بار امکان‌پذیر می‌باشد. در نهایت خروجی باید در قالب جدول و گراف عددی ارائه شود تا کاربر بتواند برای پیش‌بینی بار به آسانی از آن استفاده کند.

دسترسی اتوماتیک به اطلاعات -۵-۴-۲

اطلاعات بار پیشین، وضع هوا و بار آن در پایگاه داده‌ها ذخیره می‌شود. سیستم پیش‌بینی بار کوتاه مدت باید دسترسی اتوماتیک به پایگاه داده‌ها برای دریافت اطلاعات را داشته باشد. همینطور باید بطور اتوماتیک توانایی پیش‌بینی وضع هوا را بصورت آنلاین توسط اینترنت یا خطوط ارتباطی را داشته باشد. این امر مسئولیت کاربران را کاهش خواهد داد.

تولید اتوماتیک نتایج حاصل از پیش‌بینی -۶-۴-۲

برای کاهش ریسک عدم دقت پیش‌بینی متدهای زیادی غالباً در یک سیستم پیش‌بینی بار کوتاه مدت بکار می‌رود. در گذشته چنین سیستمی همیشه نیاز به اپراتور دارند. به عبارت دیگر اپراتورها باید برای هر مدل وزنی انتخاب کرده تا به خروجی برسند. برای راحتی بیشتر سیستم باید نتایج نهایی پیش‌بینی را با توجه به رفتار پیش‌بینی روزهای پیشین تولید نماید.

قابلیت انتقال -۷-۴-۲

سیستم‌های قدرت مختلف، منحنی بار متفاوت خاص خود را دارند. بنابراین نرمافزار معمولی پیش‌بینی بار کوتاه مدت، تنها برای منطقه‌ای که طراحی شده مناسب است. اگر یک نرمافزار پیش‌بینی بار کوتاه مدت قابلیت انتقال از یک شبکه به یک شبکه دیگر را داشته باشد تلاش اضافی برای ارائه برنامه‌ای دیگر برای منطقه‌ای دیگر صورت نخواهد گرفت. این یک نیاز اساسی در پیش‌بینی بار است که تا کنون راه حل مناسبی برایش معرفی نشده است.

۲-۵- مشکلات پیش‌بینی بار کوتاه مدت

مشکلات و موانع زیادی در پیش‌بینی بار کوتاه مدت با وجود دارند، که عبارتند از:

الف: رابطه ورودی و خروجی

ب: تعمیم تجربه کارشناسان

ج: پیش‌بینی برای روزهای خاص

د: اطلاعات ناقص و کم دقت شرایط آب و هوایی

ه: قابلیت تولید کمتر ناشی از فراپوشی

در این بخش آنها را بصورت جداگانه معرفی می‌کنیم.

۱-۵-۲ - رابطه ورودی و خروجی

بسیاری از روش‌های پیش‌بینی بار کوتاه مدت با فرض یک تابع رگرسیون (یا یک ساختار شبکه، مشابه شبکه عصبی مصنوعی) رابطه بین متغیرهای ورودی و خروجی را بیان می‌کند. مشکل اصلی طریقه فرض رگرسیون مطابق با ساختار شبکه است که نیاز به دانش قبلی از مشکل دارد. اگر فرم رگرسیون یا ساختار شبکه به گونه‌ای نامناسب انتخاب شود، نتایج پیش‌بینی راضی کننده نخواهد بود. برای مثال زمانی که مشکل از درجه دوم باشد نتایج پیش‌بینی در صورت بکارگیری رابطه خطی ورودی و خروجی بسیار ضعیف خواهد بود. مشکل مشابه دیگر انتخاب پارامتر است. نه تنها فرم تابع رگرسیون (یا ساختار شبکه) بلکه پارامترهای آن نیز باید به درستی انتخاب شوند تا نتایج مناسبی از پیش‌بینی حاصل آید. بعلاوه همواره انتخاب متغیرهای ورودی دشوار می‌باشد. کثرت متغیرها دقت پیش‌بینی را کاهش می‌دهد. باید تصمیم گرفت که در یک شرایط خاص کدام متغیر مؤثر و کدام بی‌اهمیت است و متغیرهایی که اثرشان بر رفتار بار کم است باید حذف گردند.

۲-۵-۲ تعمیم تجربه کارشناسان

پیش بینی بار دستی توسط افراد با تجربه در شبکه های قدرت در بعضی از موقع خوب بوده است. آنها حتی گاهی از پیش بینی های کامپیوتری بهترند. پس بسیار طبیعی است که از سیستم های خبره و فازی برای پیش بینی بار استفاده گردد. ولی انتقال تجربه کارشناسان بدلیل شهودی بودن پیش بینی آنها به یک پایگاه داده نظام مند، کاری بسیار مشکل است.

۳-۵-۲ پیش بینی برای روزهای خاص

بار روزهای خاص بدلیل عدم تشابه بار در مقایسه با سایر روزهای دیگر سال، اصولاً به طور دقیق قابل محاسبه نمی باشد، چرا که نمونه های کافی در دسترس نیست. این روزها شامل تعطیلات قمری، متوالی، قبل و بعد تعطیلات، روزهای بد آب و هوا یا همراه با تغییرات شدید جوی می باشند. اگرچه پیش بینی با افزایش تعداد نمونه ها شامل روزهای دور از روز مورد نظر بهبود می یابد، برای مثال بکار گیری اطلاعات مربوط به ۵ سال پیش بجای استفاده از اطلاعات یک یا دو سال پیش، رشد بار در طی گذشت سالها به تفاوت میان مصرف روزهای نمونه می انجامد. با توجه به نتایج عملی روزهایی که با تغییر ناگهانی شرایط جوی همراه است به آسانی قابل پیش بینی نمی باشد. این گونه روزها دو ویژگی، روزهای قبل از خود و ویژگی مربوط به روزهای مشابه پیشین را دارا هستند. ترکیب این دو ویژگی خود یک چالش می باشد.

۴-۵-۲ اطلاعات ناقص و کم دقت شرایط آب و هوا

از آنجا که وضع هوا تاثیری کلیدی بر نتایج حاصل از پیش بینی دارد، در بسیاری از مدل ها در نظر گرفته شده است. اگرچه تکنیک پیش بینی وضع هوا مانند پیش بینی بار در طی سال های گذشته بهبود یافته است باز هم دقت کافی را ندارد. اطلاعات غلط وضع آب و هوا در روش های پیش بینی بار کوتاه مدت می تواند به خطای بزرگی منجر شود.

مشکل دیگر این است که گاهی اطلاعات جوی با جزئیات، قابل دسترسی نیست. اطلاعات معمول وضع هوا شامل بیشترین دما، کمترین دما، متوسط رطوبت، احتمال بارندگی، حداکثر سرعت باد، شرایط جوی صبح، ظهر و عصر می‌شود.

۵-۵-۲- قابلیت تولید کمتر ناشی از فرا پوشی^۱

فراپوشی یک مشکل تکنیکی است که به منظور پیش‌بینی باید رفع شود. پیش‌بینی بار اصولاً یک مساله آموزشی و پیش‌بینی بوده که به دو مجموعه آموزش اطلاعات و آزمودن آنها مربوط است. اطلاعات آموزشی پیشین در مدل ارائه شده و یک ارائه اساسی قابل حصول بوده و به ترتیب در پیش‌بینی و تست اطلاعات بکار می‌رونند. برای مجموعه آموزشی، اگر خطای خروجی آموزش اطلاعات کم باشد ولی خطای تست اطلاعات زیاد باشد فراپوشی اتفاق می‌افتد. عیب قابل توجه شبکه‌های عصبی فراپوشی است. فراپوشی کارایی کاملی از پیش‌بینی آموزش اطلاعات را نشان می‌دهد ولی کارایی ضعیفی نیز در پیش‌بینی اطلاعات آینده دارد. از آنجا که هدف از پیش‌بینی بار کوتاه مدت، پیش‌بینی بار ناشناخته آتی است، به منظور اجتناب از فراپوشی راه حل‌های تکنیکی نیاز می‌باشد.

^۱ Over Fitting

فصل سوم

شبکه‌های عصبی

مصنوعی

۱-۳ - مقدمه

شبکه‌های عصبی را می‌توان با اغماض زیاد، مدل‌های الکترونیکی از ساختار عصبی مغز انسان نامید. مکانیسم فراغیری و آموزش مغز اساساً بر تجربه استوار است. مدل‌های الکترونیکی شبکه‌های عصبی طبیعی نیز بر اساس همین الگو بنا شده‌اند و روش برخورد چنین مدل‌هایی با مسائل، با روش‌های محاسباتی که به طور معمول توسط سیستم‌های کامپیوترا در پیش گرفته شده‌اند، تفاوت دارد. می‌دانیم که حتی ساده‌ترین مغزهای جانوری هم قادر به حل مسائلی هستند که اگر نگوییم که کامپیوترا امروزی از حل آنها عاجز هستند، حداقل در حل آنها دچار مشکل می‌شوند. به عنوان مثال، مسائل مختلف شناسایی الگو، نمونه‌ای از مواردی هستند که روش‌های معمول محاسباتی برای حل آنها به نتیجه مطلوب نمی‌رسند.

تحقیقات در این زمینه نشان داده است که مغز، اطلاعات را همانند الگوها^۱ ذخیره می‌کند. فرآیند ذخیره‌سازی اطلاعات به صورت الگو و تجزیه و تحلیل آن الگو، اساس روش نوین محاسباتی را تشکیل می‌دهند. این حوزه از دانش محاسباتی^۲ به هیچ وجه از روش‌های برنامه‌نویسی سنتی استفاده نمی‌کند و به جای آن از شبکه‌های بزرگی که به صورت موازی آرایش شده‌اند و تعلیم یافته‌اند، بهره می‌جويد. یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد. عنصر کلیدی این ایده، ساختار جدید سیستم پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق العاده بهم پیوسته به نام نرون^۳ تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کند. در شکل (۱-۳) نمائی از یک نرون طبیعی و اجزای آن نشان داده شده است [۴۰].

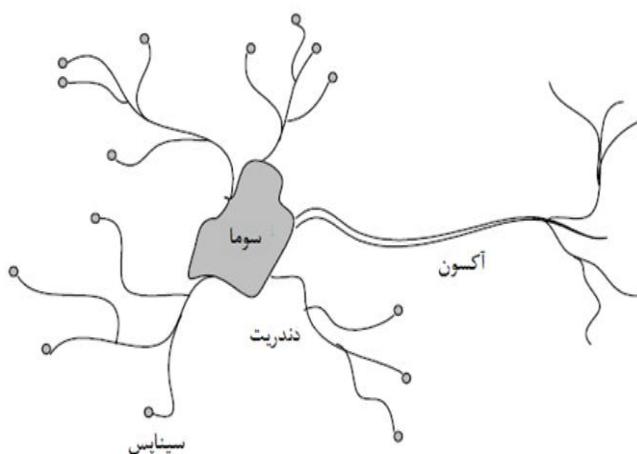
^۱ Pattern

^۲ Computation

^۳ Neuron

همان طور که در شکل مشاهده می‌شود نرون‌ها دارای چهار بخش مجزا هستند.

دندریت^۱‌ها پتانسیل الکتریکی را از سایر نرون‌ها دریافت می‌کنند. این پتانسیل‌ها توسط سیناپس^۲‌ها وزن‌دهی می‌شوند. وزن‌های داده شده توسط سیناپس‌ها می‌توانند تحريكی^۳ یا بازداری^۴ باشند. وزن تحريكی، ولتاژ پتانسیل را افزایش، و وزن بازداری، ولتاژ پتانسیل را کاهش می‌دهد. سوما^۵ یا بدنه سلول تمام پتانسیل‌های داده شده توسط دندریت‌ها را جمع می‌کند. اگر جمع تمام پتانسیل‌ها از یک مقدار معین (آستانه) تجاوز کند، سوما پتانسیل کنشی را از طریق آکسون آزاد می‌کند و به نرون دیگر تحويل می‌دهد. بعد از آزاد شدن پتانسیل کنشی، سوما ولتاژ را به پتانسیل حالت سکون برمی‌گرداند و قبل از آنکه بتواند پتانسیل دیگری را آزاد کند، لازم است مدت زمانی (دوره مقاومت^۶) را سپری نماید.



شکل - ۳ - نرون طبیعی [۴۰]

یک شبکه عصبی می‌تواند از طریق ارائه نمونه‌های آموزشی یاد بگیرد. یکی از نتایج این رویه یادگیری، قابلیت شبکه عصبی برای تعمیم و وابسته کردن داده می‌باشد. بعد از آموزش موفقیت آمیز، یک شبکه

^۱ Dendrite

^۲ Synaps

^۳ Excitatory

^۴ Inhibitory

^۵ Soma

^۶ Refactory Period

عصبی می‌تواند راهکارهای منطقی و معقولی را برای مسائل مشابه از کلاس مشابه که صریحاً آموزش دیده نشده بودند، پیدا کند. این عمل در واقع منجر به نتایجی در درجه بالایی از تحمل پذیری خطأ در مقابل داده نویزدار می‌شود.

مغز ما نیز در برابر خطاهای داخلی و خارجی تحمل پذیر می‌باشد.

به‌گونه خلاصه مشخصه‌های اصلی که ما تلاش می‌کنیم که با زیست‌شناسی تطبیق دهیم موارد زیر است:

۱- قابلیت یادگیری و خودسازماندهی^۱

۲- قابلیت تعمیم پذیری

۳- تحمل پذیری خطأ

۲-۳- تاریخچه شبکه‌های عصبی

در اوایل دهه ۴۰ میلادی، وارن مک کلاج و والتر پیتز شبکه‌هایی را طراحی کردند که به‌طور کلی اولین شبکه‌های عصبی شناخته می‌شوند. این محققان دریافتند که ترکیب تعداد زیادی نرون ساده در سیستم‌های عصبی منبع افزایش قدرت محاسباتی است. در چنین شبکه‌هایی وزن‌های نرون‌ها در طوری تنظیم می‌شوند که هر نرون نقش یک واحد منطقی ساده اجرا نماید و نرون‌های مختلف نقش‌های مختلف اجرا کنند. چنین نرون‌هایی را می‌توان در یک شبکه قرار داد تا بتوان هر خروجی را که نشانگر ترکیبی از توابع منطقی باشد، تولید کند. جریان اطلاعات در درون شبکه برای انتقال از نرونی به نرون بعدی، یک مرحله زمانی برای سیگنال انتقالی ایجاد می‌کند که این تاخیر زمانی به شبکه اجازه می‌دهد برخی از فرآیندهای فیزیولوژیکی مانند احساس گرما و سرما را مدل‌سازی کنند.

دونالد هب در سال ۱۹۴۹ اولین قانون یادگیری را برای شبکه‌های عصبی طراحی کرد. فرض او این بود که اگر دو نرون به طور هم فعال شوند، استحکام اتصال بین آنها باید افزایش یابد.

^۱ Self- organization

در سال ۱۹۵۸ فرانک روزنبلات و چندین محقق دیگر گروه بزرگی از شبکه‌های عصبی را با نام شبکه‌های پرسپترون ارائه کردند. متداول‌ترین شبکه پرسپترون متشکل از یک لایه بود که با مسیرهایی با وزنهایی به نرون‌های پیوند دهنده متصل می‌شد و وزن‌های مسیرهای اتصال قابل تنظیم بودند. قانون یادگیری پرسپترون از روشی تکرار شونده برای تنظیم وزن استفاده می‌کند که بسیار قوی‌تر از قانون هب است. اگر وزن‌هایی برای جواب مسئله نظر وجود داشته باشند آنگاه می‌توان ثابت کرد که یادگیری پرسپترون به وزن‌های صحیح همگرا می‌شود یعنی این قانون یادگیری این امکان را به شبکه می‌دهد که تمام جفت‌های ورودی آموزش و خروجی هدف معادل را دوباره به طور صحیح تولید کند. روزنبلات در کار سال ۱۹۶۲ انواع بسیاری از شبکه‌های پرسپترون را توضیح می‌دهد. همانند نرون‌هایی که مک‌کلاچ و پیتز و هب ساخته‌اند، پرسپترون‌ها نیز از یک تابع خروجی آستانه استفاده می‌کنند.

برنارد ویدرو و دانشجوی او مارسیان هاف در سال ۱۹۶۰ یک قانون یادگیری ارائه کردند که ارتباط نزدیکی با قانون یادگیری پرسپترون دارد و معمولاً یا نام آنها رو با خود دارد (قانون ویدرو-هاف^۱) یا میانگین مربعات کمینه^۲ یا قانون دلتا^۳ نامیده می‌شود. در قانون پرسپترون برای هر واحدی که پاسخ نادرست دارد، وزن‌های اتصال آن واحد تنظیم می‌شود، اما قانون دلتا وزن‌ها را طوری تنظیم می‌کند تا اختلاف بین خروجی شبکه و خروجی مطلوب را کاهش دهد که این امر منجر به کمترین میانگین مربعات خطای شود. علی‌رغم این که تفاوت قانون یادگیری ویدرو-هاف با قانون پرسپترون کم است، اما قانون دلتا منجر به افزایش قابلیت تعمیم شبکه می‌شود. قابلیت تعمیم به شبکه این امکان را می‌دهد که به ورودی‌هایی نیز که مشابه، اما نه یکسان، با ورودی‌های آموزش داده شده به شبکه هستند، پاسخ دهد. قانون یادگیری ویدرو-هاف برای شبکه‌ی یک لایه، پیش درآمد قانون پس

^۱ Widrow-Hoff Rule

^۲ Least Mean Square (LMS)

^۳ Delta Rule

انتشار^۱ برای شبکه های چند لایه است. کاری که ویدرو و دانشجویانش انجام داده اند، گاهی اوقات تحقیق در مورد شبکه های عصبی و گاهی نیز سیستم های خطی و فقی (طبیقی) به شمار می آید. اغلب به این شبکه ها نام آدالاین اطلاق می شود که می توان آن را نرون خطی و فقی یا سیستم خطی و فقی تفسیر کرد.

اولین اثر توو کوهون در سال ۱۹۷۲ به شبکه های عصبی حافظه‌ی پیوندی می‌پرداخت. کار بعدی وی در سال ۱۹۸۲ توسعه‌ی نگاشتهای خودسازمانده بود که در آن از ساختارهای توپولوژیکی در خوشبندی برای واحدهای خوشه‌ها استفاده شده است.

جیمز آندرسن نیز در طی سال‌های ۱۹۶۸ تا ۱۶۷۲ تحقیق خود در زمینه‌ی شبکه‌هایی عصبی را با شبکه‌های حافظه‌ی انجمانی آغاز کرد. وی نظریاتش را در اثر خود با نام حالت مغز در یک جعبه^۲ را در سال ۱۹۷۷ ارائه کرد که در آن خروجی خطی مدل‌های اولیه را برای جلوگیری از بزرگ شدن بیش از حد خروجی، هم‌زمان با تکرار شبکه جهت یافتن راه حل یا حافظه پایدار کوتاه می‌کند.

روش پس‌انتشار خطا که پرکاربردترین الگوریتم آموزش پرسپترون‌های چند لایه است، قبل از این که معروفیت زیادی پیدا کند توسط دیوید پاکر در سال ۱۹۸۵ و لوکان در سال ۱۹۸۶ به طور جداگانه کشف شده بود. به علاوه، این روش مشابه الگوریتمی قدیمی در نظریه‌ی کنترل بهینه است. کار پارکر مورد توجه گروه پردازش توزیع شده موازی با رهبری دیوید روملهارت و جیمز مک‌کلاند قرار گرفت که آن را اصلاح و منتشر کردند.

جان هاپفلید به همراه دیوید تانک در طی سال‌های ۱۹۸۲ تا ۱۹۸۷ تعدادی شبکه‌ی عصبی براساس وزن‌های ثبات و فعال سازی وقفی ایجاد کرد. این شبکه‌ها را می‌توان جزو شبکه‌های حافظه‌انجمانی به

^۱ Back Propagation (BP)

^۲ Brain State in a Box

حساب آورد و از آنها در حل مسائل ارضای محدودیت^۱، هم چون مسئله‌ی فروشنده‌ی دوره گرد، استفاده کرد.

در طی سال‌های ۱۹۸۳ تا ۱۹۸۷ تعدادی از محققان شبکه‌هایی به نام ماشین بولتزمن را به وجود آورند که در آنها وزن‌ها یا فعال سازی براساس تابع تراکم احتمال تغییر می‌کند. در این شبکه‌ها از ایده‌های کلاسیکی هم‌چون شبیه‌سازی سردشدن تدریجی^۲ و تئوری تصمیم گیری بیز^۳ استفاده می‌شود [۴۱].

۳-۳- کاربرد شبکه‌های عصبی مصنوعی

با توجه به ویژگی‌های شبکه‌های عصبی در شبیه‌سازی و تحلیل مسائل پیچیده و از طرفی وجود پدیده‌های متعدد مبهم و ناشناخته در طبیعت که انسان ناگزیر از رویارویی و حل آنها می‌باشد. همواره لزوم استفاده از شبکه‌های عصبی مصنوعی به عنوان ابزاری توانمند در رفع این نیاز احساس می‌شود. از این‌رو گستره وسیعی از مسایل فنی و مهندسی و حتی اجتماعی را در برگرفته است. از جمله، امور پیش‌بینی، سیستم‌های هوافضا، اتوماسیون وسایل، امور مالی و بانکداری، صنایع دفاعی و امنیتی، نقل و انتقال، علوم پزشکی و درمانی، وسایل ارتباط جمعی، علوم صنایع غذایی و کشاورزی، امور مربوط به آب و هزاران مقوله دیگر که به نحوه چشمگیری رواج دارد. با وجود کاربردهای متعدد شبکه عصبی مصنوعی، می‌توان آنها را از نظر نوع کارکرد به سه دسته تقسیم بندی نمود:

^۱ Constraint Satisfaction

^۲ Simulated Annealing

^۳ Bayesian Decision Theory

۱-۳-۳ تشخیص الگو^۱

در بسیاری از علوم برای هر پدیده و رخداد، نشانه‌ها و الگوهای وجود دارد که با استفاده از شبکه عصبی می‌توان از طریق دریافت الگوهای محرک به پاسخ و یا همان تشخیص پدیده دست یافت. مانند این‌که از نشانه‌های خاص یک بیماری به تشخیص آن برسیم.

۲-۳-۳ تقریب تابع

یکی از کاربردهای شبکه عصبی مصنوعی، پردازش یک تابع خطی یا غیر خطی میان پارامترهای معلوم و مجهول مساله می‌باشد و به عبارت دیگر، شبکه می‌تواند برازش خطی یا غیر خطی با رابطه مشخص را میان پارامترهای معلوم و مجهول مساله انجام دهد.

۳-۳-۳ شناسایی ساختار

بعضی با در نظر گرفتن یک فرآیند ناشناخته و استفاده از شبکه عصبی مصنوعی به موازات آن، با ورود یک سری داده‌های معلوم، پاسخ شبکه را با داده‌های مشاهده ای موجود مقایسه می‌نماییم و در ادامه با توجه به اختلاف میان پاسخ و خروجی ساختار اصلی، شبکه آموزش دیده و با دقت مورد نظر می‌تواند ساختار و رابطه بین ورودی و خروجی واقعی را شناسایی کند.

۴-۳ روند استفاده از شبکه‌های عصبی مصنوعی

به طور کلی استفاده از شبکه‌های عصبی مصنوعی شامل دو مرحله زیر است:

۱-۴-۳ مرحله آموزش

یعنی پردازش یا عملی که از تحریک پیوسته شبکه، منجر به تنظیم پارامترهای مستقل (وزن‌های اتصال سلول‌ها) شبکه گردد. عمدۀ روش‌های آموزش برای استفاده از شبکه‌های عصبی مصنوعی شامل چهار

^۱ Pattern Recognition

روش: آموزش نظارت شده، آموزش نظارت نشده، آموزش تقویت شده و یادگیری روی خط و خارج خط می باشد که در ادامه تشریح می گردد.

۱-۴-۱-۳ آموزش نظارتی^۱ (با معلم)

این روش تنها در موقعی استفاده می شود که از پیش، بعضی مسایل مورد نظر به وسیله روش های دقیق حل شده و پاسخ آنها در اختیار باشد. در این روش یکی از ورودی ها که خروجی آن معلوم باشد به شبکه اعمال شده و خروجی متناظر آن از شبکه دریافت می گردد. پس بین خروجی حاصل از شبکه و خروجی واقعی مقایسه صورت گرفته و بر اساس تفاوت آنها، به تصحیح وزن ها پرداخته می شود. این محاسبات تا زمانی که وزن های اتصال ثابت شوند تکرار می گردد.

در اینجا می خواهیم یک نگاه کلی به یادگیری نظارتی بیندازیم که دارای مراحل زیر می باشد:

۱- وارد کردن الگوهای ورودی (فعال سازی نرون های ورودی) قابلیت تعمیم پذیری

۲- انتشار رو به جلوی ورودی از طریق شبکه و تولید خروجی

۳- مقایسه خروجی با خروجی مطلوب و ایجاد بردار خطا

۴- تصحیح شبکه با توجه به بردار خطا

۵- بکارگیری مقادیر تصحیح شده

۱-۴-۲-۲ آموزش نظارت نشده^۲ (بدون معلم)

در این روش آموزش دهنده ای وجود ندارد و به نسبت هیچ یک از ورودی ها، خروجی مطلوبی نخواهیم داشت. تنها موردی که در این مرحله کار آموزش را انجام می دهد این است که یک سری معیار و محدودیت به شبکه تحمیل شود. سپس شبکه به ازای هر ورودی، خروجی متناظر آن را به

¹ Supervised Learning

² Unsupervised Learning

دست آورده و آنگاه به سراغ معیارهای مطلوب می‌رود. اگر معیارهای مورد نظر رعایت شده باشد، کار آموزش به پایان رسیده و در غیر این صورت آن قدر وزن‌ها تغییر داده می‌شوند تا به معیار مورد نظر برسد.

آموزش تقویت شده -۳-۱-۴-۳

در این روش با یک سری وزن‌های دلخواه، خروجی‌ها محاسبه می‌شوند. چنانچه خروجی به دست آمده به معیار مورد نظر نزدیک باشد، ضرائب تغییر نکرده و شبکه تشویق می‌شود. در صورتی که از معیارهای دور شده باشد، ضرائب عوض می‌شوند(در اصطلاح شبکه تنبیه می‌شود).

یادگیری روی خط^۱ و خارج خط^۲ -۴-۱-۴-۳

یادگیری می‌تواند به صورت روی خط باشد، به این معنی که مجموعه‌ای از نمونه‌های آموزشی ارائه می‌شود، سپس وزن‌ها تغییر می‌یابد و خطای کل از طریق محاسبه یک تابع خط، محاسبه می‌شود. افزون بر یادگیری روی خط ، یادگیری می‌تواند به صورت خارج خط نیز باشد، به این صورت که پس از ارائه هر ورودی، وزن‌ها تغییر می‌یابند. یادگیری روی خط، یادگیری دسته‌ای^۳ نیز نامیده می‌شود. زیرا در این روش دسته‌ای از نتایج در یک زمان تصحیح می‌شوند. به این قسمت از آموزش که شامل تصحیح و یادگیری کل ورودی‌ها می‌باشد اپک^۴ یا دوره آموزشی گفته می‌شود.

الگوهای ورودی و آموزش ورودی‌ها -۲-۴-۳

در یادگیری با ناظر، مجموعه یادگیری به زوج مرتب (P_i , T_i) برای هر نرون ورودی گفته می‌شود که در آن P_i الگوی ورودی نرون i -ام و T_i مقدار مطلوب متناظر با الگوی ورودی شماره i می‌باشد.

¹ On Line

² Off Line

³ Batch Learning

⁴ Epoch

خروجی نرون خروجی شماره i را با O_i نشان می‌دهیم. برای هر نرون i یک مقدار E_i نیز وجود دارد که نشان دهنده خطای الگوی شماره i می‌باشد و در حالت کلی بردار خطای E به صورت زیر می‌باشد:

$$E_p = \begin{pmatrix} T_1 - O_1 \\ \vdots \\ T_n - O_n \end{pmatrix} \quad (1-3)$$

تقسیم الگوهای آموزشی - ۱-۲-۴-۳

یک راهکار که بیشتر پیشنهاد می‌شود، تقسیم بندی مجموعه آموزشی به دو مجموعه زیر می‌باشد:

- ۱- یک مجموعه به طور کامل برای آموزش در نظر گرفته شود.
- ۲- یک مجموعه دیگر برای تست در نظر گرفته شود. به‌گونه‌ای که نمونه آموزشی کافی وجود داشته باشد. تقسیم بندی رایج به این صورت است که ۸۰٪ از نمونه‌های ورودی برای آموزش و ۲۰٪ برای تست استفاده شوند. ما می‌توانیم آموزش را وقتی که شبکه نتایج خوبی را روی داده آموزشی ارائه می‌دهد تمام کنیم. اما اگر داده‌های تست نتایج ضعیفی را نشان دهند، ساختار شبکه را تغییر ندهید تا این‌که این داده‌های تستی نتایج خوبی را نشان دهند. زیرا در غیر اینصورت اینکار مانند این است که داده‌های تستی نیز در واقع به صورت داده‌های آموزشی در نظر گرفته شده‌اند. راهکار این است که سومین داده‌های تستی را ایجاد کنیم به‌گونه‌ای که تنها برای تست استفاده شوند، پس از این‌که دوره‌های آموزشی موفقیت آمیزی انجام شد.

ترتیب ارائه الگوها - ۲-۲-۴-۳

راهکارهای مختلفی برای ترتیب نمایش الگوها وجود دارد:

اگر الگوها با یک ترتیب تصادفی ارائه شوند، هیچ تضمینی وجود ندارد که الگوها همه به‌گونه مساوی به خوبی آموزش داده شوند. وقتی که در حال استفاده از شبکه‌های بازگشتی هستیم، ارائه ترتیب مشابهی از

الگوها این خطر را دارد که الگوها توسط شبکه حفظ شوند. یک جایگشت تصادفی هر دو مشکل را حل می‌کند اما این کار یک رویه وقت‌گیر است.

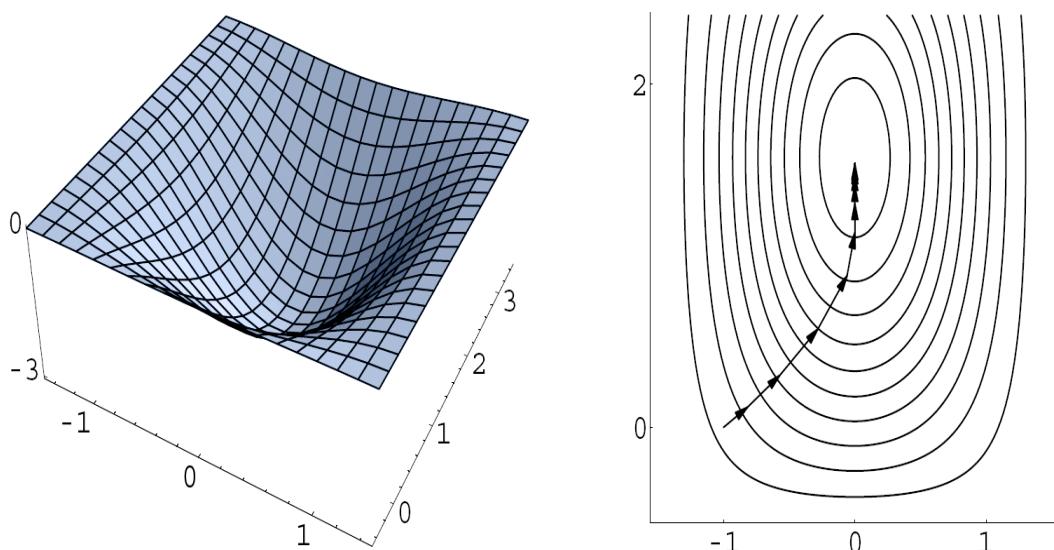
۳-۴-۳- توقف یادگیری

سؤال اصلی این است که، چه موقع یادگیری را متوقف کنیم؟ اصولاً یادگیری وقتی متوقف می‌شود که مقدار خطأ کوچک شده باشد که باز هم این کوچک شدن به منحنی یادگیری وابسته است، یا وقتی یادگیری را متوقف کنیم که خطأ از یک مقدار آستانه کمتر شده باشد.

۳-۴-۳- رویه‌های بهینه‌سازی گرادیان

رویه‌های گرادیان نزولی موقعی به کار گرفته می‌شوند که ما بخواهیم یکتابع n بعدی را کمینه یا بیشینه کنیم. در شکل (۳-۲) حالت‌هایی از گرادیان نزولی در مورد توابع دوبعدی وجود دارد، اما هیچ محدودیتی روی بعد توابع وجود ندارد.

گرادیان یک بردار \vec{g} است که برای هر نقطه مشتق پذیر تابع تعریف شده است. بنابراین، گرادیان تعمیمی از مشتق پذیری برای توابع چندبعدی می‌باشد. گرادیان نزولی یعنی نقاطی به سمت پرشیب ترین کمینه یا کمینه مطلق [۴۳].



شکل ۳-۲- حالت‌هایی از گرادیان نزولی در مورد توابع دوبعدی [۴۳]

مشکلات رویه‌های گرادیان:

گرادیان نزولی روش رضایت بخشی است اما برای نمونه در موقعی که خطای وجود دارد، یک جواب را همیشه آشکار نمی‌کند. مشکلات گرادیان عبارتند از:

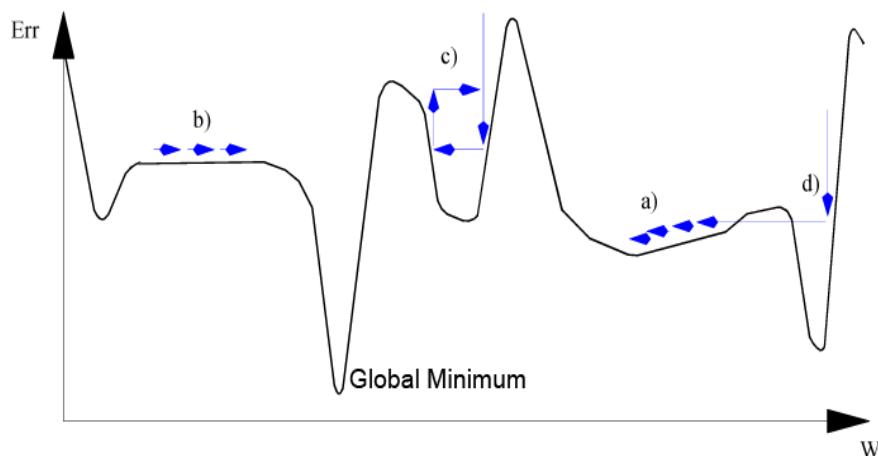
۱- همگرایی به سمت کمینه محلی: هر رویه گرادیان نزولی می‌تواند در یک کمینه محلی گیر کند.

این مشکل تا حد زیادی وابسته به سایز سطح خطای باشد و هیچ راهکار عمومی برای آن وجود ندارد. این موضوع در قسمت a از شکل (۳-۳) دیده می‌شود.

۲- قرار گرفتن در نقاط صاف: وقتی که در حال عبور از یک ناحیه صاف هستیم، گرادیان بسیار کند کوچک می‌شود، بنابراین به مراحل بیشتری نیاز داریم. این موضوع در قسمت b از شکل (۳-۳) دیده می‌شود.

۳- ترک کردن کمینه‌های خوب: از طرف دیگر، گرادیان در یک شیب تند، بسیار سریع کاهش می‌یابد، بنابراین این گام‌های بزرگ باعث از دست دادن کمینه‌های مناسب می‌شوند. این موضوع در قسمت c از شکل (۳-۳) دیده می‌شود.

۴- نوسان کردن در یک دره باریک: یک ورود ناگهانی از یک گرادیان منفی بسیار قوی به طرف یک گرادیان مثبت بسیار قوی می‌تواند منجر به به نوسان شود. این مطلب در قسمت d از شکل (۳-۳) مشاهده می‌شود [۴۳].



شکل ۳-۳- مشکلات ممکن در گرادیان نزولی [۴۳]

مرحله بازخورد -۴-۴-۳

پس از آموزش، با معرفی هر بردار ورودی شبکه خروجی متناظر آن به دست می‌آید که مرحله بازخورد نام دارد. لازم به ذکر این که آموزش شبکه تنها یک بار انجام می‌گیرد، ولی در مرحله بازخورد می‌توان به ازای ورودی‌های مختلفی که به شبکه داده می‌شود، خروجی مطلوب را از آن دریافت نمود.

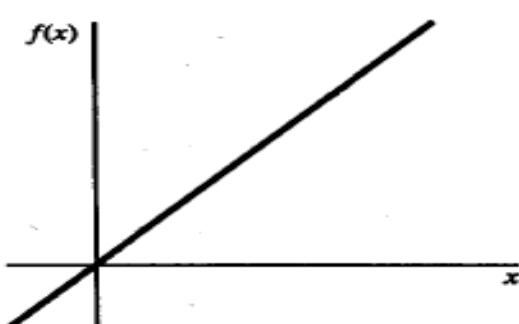
۱-۵-۳- توابع فعالیت (تبديل)^۱

در تمامی شبکه‌های عصبی مصنوعی، هر سلول دارای تابعی است که نشان دهنده رفتار آن سلول عصبی بوده و تابع فعالیت نامیده می‌شود. شماری از توابع فعالیت که در شبکه‌های عصبی مصنوعی کاربرد دارند در ادامه آورده شده‌اند [۴۱].

-۱-۵-۳- تابع همانی^۲ (خطی)

این نوع تابع بیشتر در شبکه‌های تک لایه کاربرد دارد و چنانچه در تمامی لایه‌های یک لایه شبکه چند لایه استفاده شود، شبکه چند لایه همانند یک شبکه تک لایه عمل خواهد نمود. تابع همانی به صورت زیر بیان می‌شود.

$$f(x) = x \quad \text{for all } x \quad (2-3)$$



شکل ۳-۴- تابع همانی [۴۱]

^۱ Transfer or Activation Functions

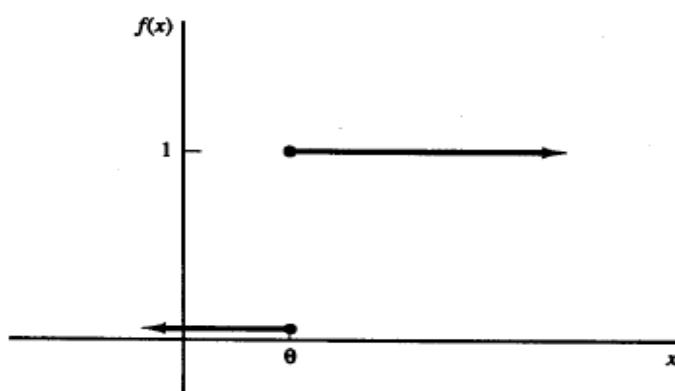
^۲ Purelin

-۲-۵-۳

تابع پله‌ای دودویی (با آستانه θ)

تابع پله‌ای دودویی به عنوان تابع آستانه یا تابع هیوساید هم شناخته می‌شود. در شکل (۳-۵) نشان داده شده است.

$$f(x) = \begin{cases} 1 & \text{if } x > \theta \\ 0 & \text{if } x < \theta \end{cases} \quad (3-3)$$



شکل -۳-۵- تابع پله‌ای دودویی [۴۱]

-۳-۵-۳

تابع سیگموید دودویی^۱ (سیگموید لجستیک)

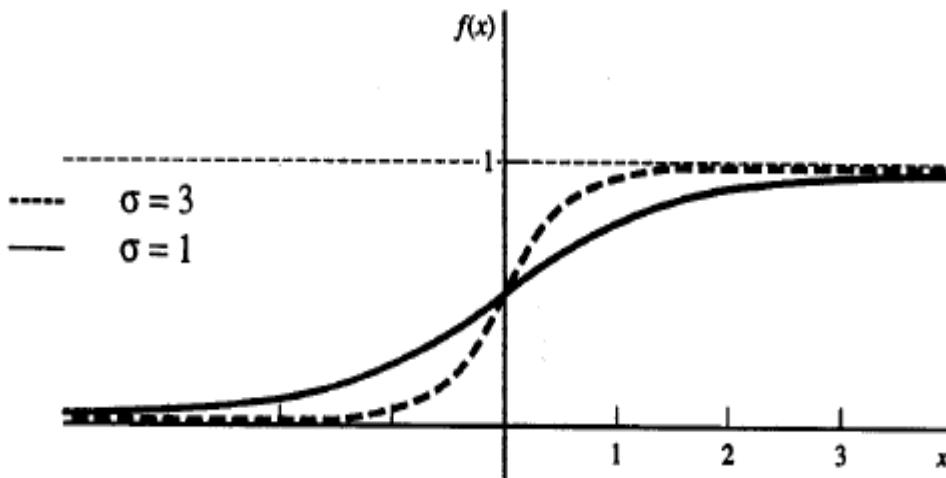
تابع سیگموید، توابع فعال‌سازی سودمند و پرکاربردی هستند که متداول‌ترین آن تابع لجستیک^۲ و تابع تانژانت هیپربولیک هستند. این توابع مزایای ویژه‌ای برای استفاده در شبکه‌های عصبی‌ای که با روش پساننتشار آموزش داده می‌شوند، دارند. چون در این توابع ارتباط ساده‌ای بین مقدار تابع در یک نقطه و مقدار مشتق آن تابع در همان نقطه وجود دارد. این مسئله باعث می‌شود که با محاسباتی پساننتشار در حین آموزش کاهش یابد. این تابع با دامنه $[-\infty, +\infty]$ ، اغلب به عنوان تابع فعال‌سازی برای شبکه‌های عصبی‌ای که در آنها مقادیر مطلوب خروجی یا دودویی است و یا در بازه بین 0 و 1 قرار می‌گیرد، استفاده می‌شود. این تابع در شکل (۳-۶) برای دو مقدار از پارامتر شیب σ نشان داده شده است.

^۱ Binary Sigmoid

^۲ Logistic Function

$$f(x) = \frac{1}{1+\exp(-\sigma x)} \quad (4-3)$$

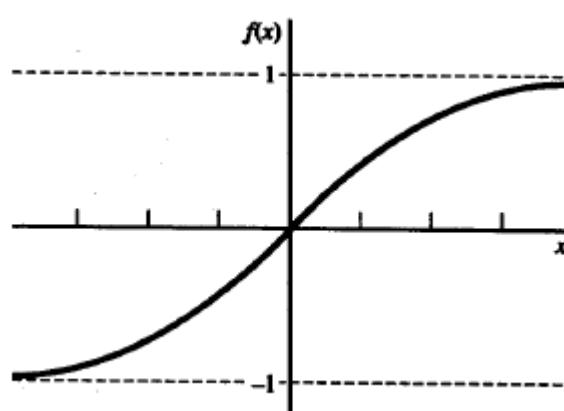
$$f'(x) = \sigma f(x)[1-f(x)] \quad (5-3)$$



[۴۱] شکل ۳-۶ - تابع سیگمویید دودویی با پارامترهای شیب $\sigma = 1$ و $\sigma = 3$

تابع سیگمویید دوقطبی - ۴-۵-۳

تابع سیگمویید را می‌توان طوری مقیاس‌بندی کرد که هر دامنه از مقادیر را که برای یک مسئله خاص مناسب است، دارا باشد. متداول‌ترین دامنه برای این تابع از -1 تا 1 است که ما این تابع سیگمویید را سیگمویید دوقطبی می‌نامیم. این تابع برای $\sigma = 1$ در شکل (۷-۳) نشان داده شده است.



[۴۱] شکل ۳-۷ - تابع سیگمویید دوقطبی با شیب $\sigma = 1$

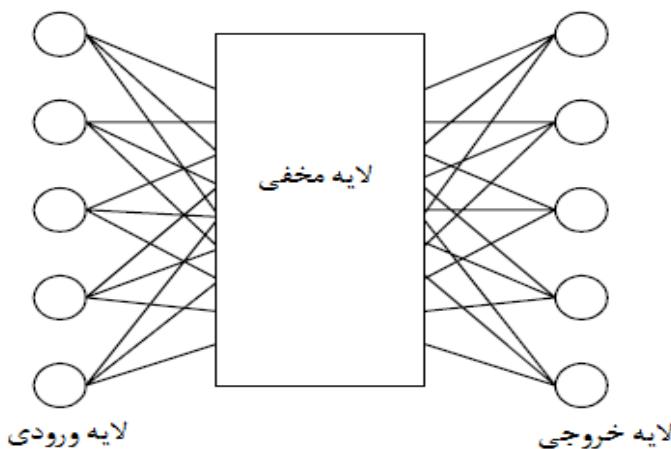
$$g(x) = \frac{1 - \exp(-\sigma x)}{1 + \exp(-\sigma x)} \quad (6-3)$$

$$g'(x) = \frac{\sigma}{2} [1 + g(x)][1 - g(x)] \quad (7-3)$$

۶-۳ ساختار شبکه عصبی مصنوعی

نرون به عنوان کوچکترین واحد پردازش داده در یک شبکه عصبی مصنوعی، اساس عملکرد رفتار آن را نشان می‌دهد. از ترکیب چند نرون سلول ساخته می‌شود که بسته به نوع سلول وظیفه خاصی را در شبکه عهده‌دار است. چگونگی اتصال سلول‌های عصبی در لایه‌های مختلف، مشخص‌کننده ساختار شبکه است که معماری شبکه نام دارد.

به‌گونه رایج ساختار هر شبکه عصبی به‌گونه‌ای است که در لایه ورودی^۱ سلول‌های دریافت کننده و در لایه‌های میانی (پنهان) سلول‌های پردازشگر قرار می‌گیرند. لایه خروجی هم در برگیرنده سلول‌هایی است که افزون بر پردازش اطلاعات، پاسخ شبکه را نیز نشان می‌دهند. لایه‌های شبکه توسط پیوست هایی با وزن‌های متفاوت به هم متصل هستند. شکل (۸-۳) ساختار کلی یک شبکه عصبی را نشان می‌دهد.



شکل ۳-۸- ساختار کلی یک شبکه عصبی [۴۰]

^۱ Input Layer

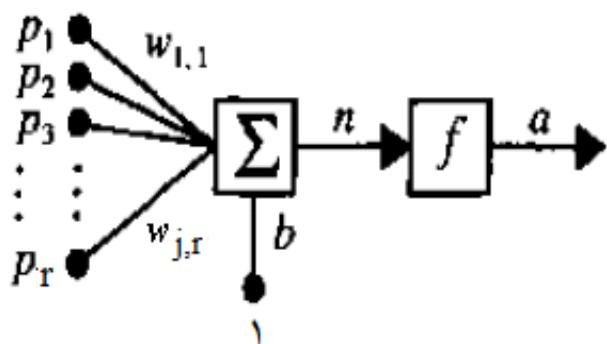
عملکرد شبکه چنان که در شکل (۹-۳) نشان داده شده، به صورتی است که از مجموع حاصلضرب ماتریس ورودی p با عناصر (p_1, p_2, \dots, p_r) و ماتریس وزن W با عناصر $(w_{i,j})$ نسبت داده شده به هر یک از اتصال‌های ورودی نرون و مقدار ثابت یک با وزن b ، ورودی خاص نرون n را به صورت رابطه (۸-۳) می‌دهد.

$$n = \sum_{i=1}^r P_I W_{i,I} + b = WP + b \quad (8-3)$$

در رابطه (۸-۳)، r شمار ورودی و b وزن اریب^۱ نرون نامیده می‌شود. در نهایت خروجی نرون به صورت زیر خواهد بود:

$$a = f(WP + b) \quad (9-3)$$

پارامترهای w و p قابل تنظیم بوده و تابع f نیز توسط شخص طراح انتخاب می‌گردد. با انتخاب یک ساختار مناسب یا همان معماری درست شبکه، یعنی قرار دادن اصولی و صحیح تمامی اجزا و معرفی تابع فعالیت و قانون آموزش مناسب آن، می‌توان شبکه را در راستای دستیابی به هدف مورد نظر آموزش داد و رفتار و پاسخ مطلوبی دریافت نمود.



شکل ۳-۹- ساختار نرون با r ورودی [۴۲]

^۱ Bias Weight

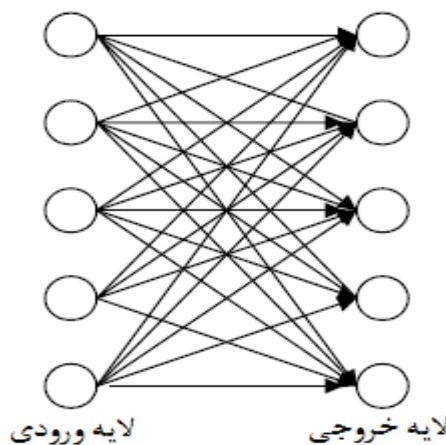
۱-۶-۳- شبکه های پیشخورد تک لایه^۱

قبل از معرفی این شبکه، لازم است دو واژه پسخورد و پیشخورد تشریح شوند که مبنای تقسیم بندی انواع شبکه از نظر رفتار هستند.

الف) پسخورد: وضعیتی است که بتوان در شبکه حداقل یک حلقه را پیدا کرد به گونه‌ای که در آن سیگنال از یک سلول به خودش برگردد.

ب) پیشخورد^۲: حالتی است که در آن خروجی هر سلول تنها به سلول های لایه بعد متصل است و از سلول های لایه قبل تاثیر نمی‌پذیرد.

شبکه پیشخورد تک لایه، شبکه هایی هستند که مطابق شکل (۱۰-۳) دارای هیچ لایه میانی (لایه مخفی) و تنها یک لایه ورودی و خروجی دارد.



شکل ۳ - ۱۰ - ساختار کلی شبکه پیشخورد تک لایه [۴۰]

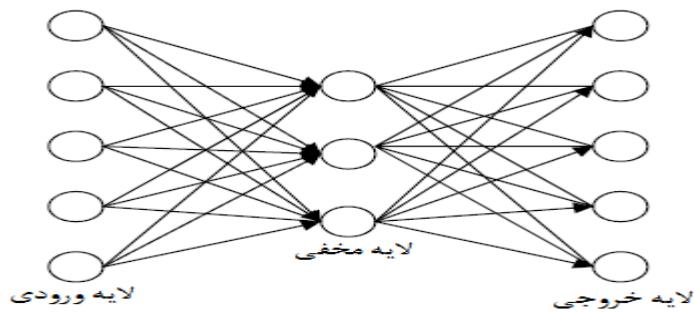
۲-۶-۳- شبکه های پیشخورد چند لایه^۳

این نوع شبکه ها با اضافه نمودن یک یا چند لایه میانی(پنهان) به نوع تک لایه ساخته می شوند که ساختار به صورت شکل زیر دارند.

^۱ Single Layer Feed-Forward Networks

^۲ Feed Forward

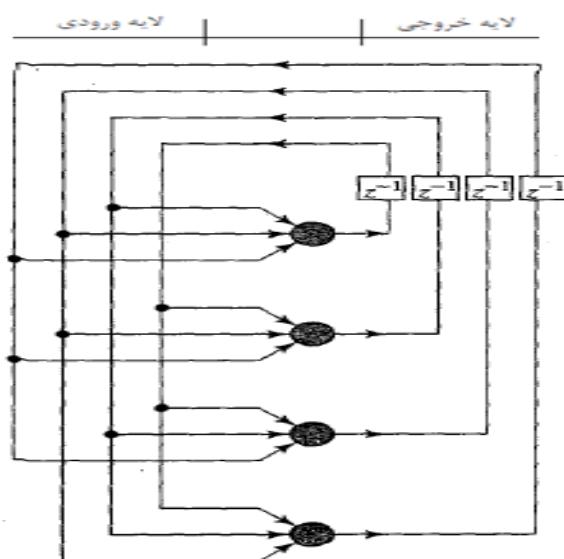
^۳ Multi Layer Feed-Forward Networks



شکل ۳-۱۱- ساختار کلی شبکه پیشخورد چند لایه [۴۰]

۳-۶-۳ شبکه های برگشتی

به شبکه هایی برگشتی گفته می شود که دارای حداقل یک برگشت از خروجی باشند. یعنی لایه ستانده در این شبکه ها افزون بر اتصال ورودی، از بردار خروجی نیز تاثیر می پذیرد. شکل (۳-۱۲) نمونه ای از این نوع شبکه را نشان می دهد که در آن عامل z نشانگر تاخیر زمانی شبکه است.

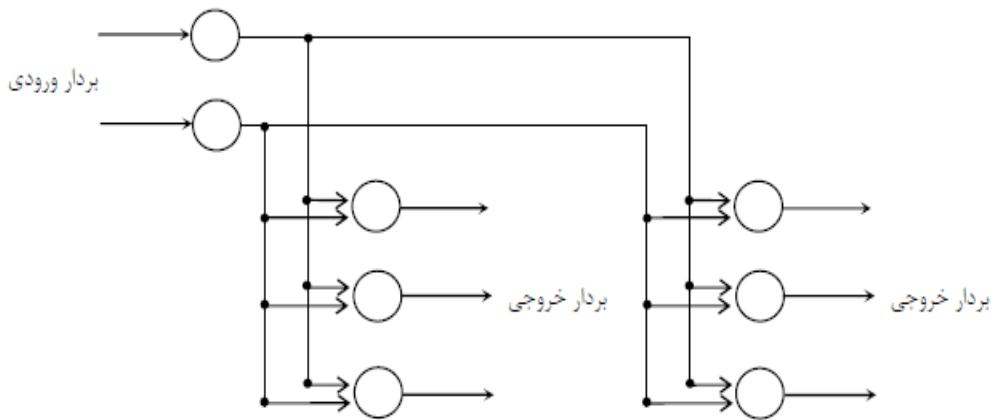


شکل ۳-۱۲- ساختار کلی شبکه برگشتی [۴۴]

۴-۶-۳ ساختارهای مشبک^۱

شبکه هایی ساختار مشبک دارند که در آنها بردار خروجی آن گونه ای که در شکل (۱۳-۳) نشان داده شده، شامل خروجی تمامی سلول های موجود در شبکه باشد.

^۱ Lattice Structure



شکل ۳-۱۳- ساختار کلی شبکه ها با ساختار مشبک

۷-۳- شبکه عصبی پس انتشار

۱-۷-۳- شبکه پس انتشار استاندارد

مادر این بخش در مورد روش آموزش پس انتشار خطای قانون دلتای تعمیم یافته نامیده می شود. این روش همان روش کاهش گرادیان برای به حداقل رساندن کل مربعات خطای خروجی محاسبه شده توسط شبکه است. به شبکه عصبی چند لایه ای که با روش پس انتشار خطای آموزش داده می شود، شبکه پرسپترون چند لایه^۱ نیز می گویند.

به طور کلی در همه کاربردهایی که شامل حل مسئله نگاشت مجموعه ای از ورودی ها به مجموعه مشخصی از خروجی های هدف است که منجر به آموزش با نظارت می شود، می توان از شبکه های پس انتشار استفاده نمود.

مانند اکثر شبکه های عصبی دیگر، هدف آموزش شبکه با پس انتشار، رسیدن به تعادل بین قابلیت یادگیری و تعمیم است. منظور از قابلیت یادگیری پاسخ گویی صحیح به الگوهای ورودی به کار رفته برای آموزش است، و منظور از تعمیم، پاسخ دهنده منطقی به ورودی های شبیه اما نه دقیقا یکسان با، ورودی به کار رفته در آموزش است.

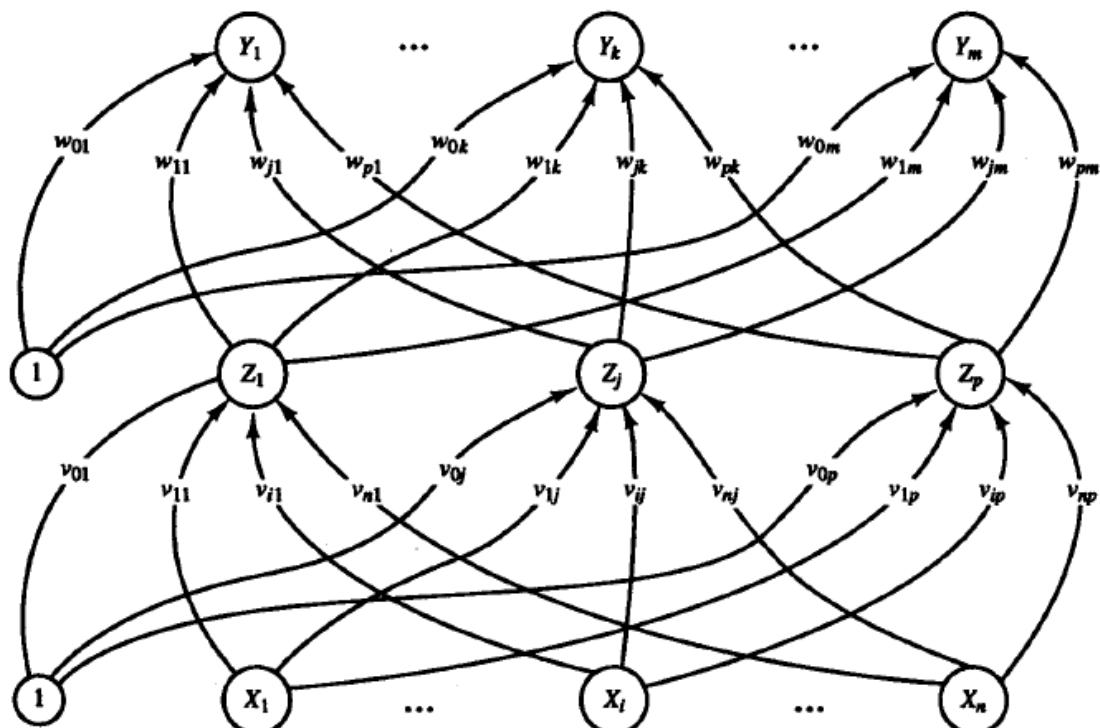
^۱ Multi Layer Perceptron(MLP)

آموزش یک شبکه با الگوریتم پس انتشار شامل سه مرحله پیش خور کردن الگوی آموزش ورودی، محاسبه و پس انتشار کردن خطای مربوط، و تنظیم وزن ها است. بعد از آموزش، شبکه فقط محاسبات مرحله پیش خور خود را لازم دارد. این بدان معناست که حتی اگر آموزش شبکه نیازمند زمان زیادی باشد، شبکه آموزش دیده می تواند در فاز استفاده، خروجی خود را با سرعت زیاد تولید کند. انواع متعددی از الگوریتم های پس انتشار نیز به منظور بهبود فرآیند یادگیری توسعه یافته است.

بر خلاف شبکه یک لایه که دارای محدودیت زیادی در یادگیری نگاشتها است، شبکه چند لایه می تواند هر نگاشت پیوسته‌ای را با دقت دلخواه یاد بگیرد. هر چند در این شبکه‌ها در اغلب موارد یک لایه مخفی کافی است، اما ممکن است برای برخی کاربردها بیش از یک لایه مخفی استفاده شود [۴۱].

-۱-۱-۷-۳ ساختار

ساختار کلی یک شبکه چند لایه پس انتشار در شکل (۱۴-۳) نشان داده شده است.



شکل ۳-۱۴ - ساختار یک شبکه عصبی پس انتشار با یک لایه مخفی [۴۱]

در شبکه عصبی نشان داده شده در این شکل، یک لایه ورودی (واحدهای X)، یک لایه شامل واحدهای مخفی (واحدهای Z)، و یک لایه خروجی (واحدهای Y) نشان داده شده است. همان‌طور که در این شکل دیده می‌شود، واحدهای خروجی و واحدهای مخفی می‌توانند با یا اس نیز داشته باشند. با یا اس روی واحد Y_k با w_{kj} نشان داده شده است و با یا اس روی واحد مخفی Z_j با v_{kj} مشخص شده است. این با یا اس‌ها همانند وزن‌های روی اتصالات از واحدهایی که خروجی آنها همیشه ۱ است، عمل می‌کنند. در این شکل، فقط جهت جریان اطلاعات برای مرحله پیش‌خور عملیات نشان داده شده است. در مرحله پس‌انتشار یادگیری، سیگنال‌ها در جهت عکس از لایه خروجی به لایه ورودی فرستاده می‌شوند.

الگوریتم پس‌انتشار - ۲-۱-۷-۳

در مرحله پیش‌خور، هر ورودی i یک سیگنال ورودی دریافت می‌کند و این سیگنال‌ها را به هر یک از واحدهای Z_p می‌فرستد. سپس هر واحد مخفی، فعال‌سازی خود را محاسبه می‌کند و سیگنال خود، Z_i ، را به همه واحدهای خروجی می‌فرستد. هر واحد خروجی Y_k فعال‌سازی خود را (برابر با y_k) محاسبه می‌کند تا پاسخ شبکه را برای الگوی ورودی ارائه شده تشکیل دهد.

در آموزش با نظارت برای هر الگوی ورودی یک مقدار هدف نیز در دسترس است. در حین آموزش با پس‌انتشار، هر واحد خروجی فعال‌سازی محاسبه شده y_k خود را با مقدار هدف خود، t_k ، مقایسه می‌کند تا خطای مربوط آن الگو برای آن واحد را مشخص کند. براساس این خطای عامل δ_k که در ادامه تشریح می‌شود، برای توزیع کردن مقدار خطای واحد خروجی Y_k به تمام واحدهای لایه قبل (واحدهای مخفی که به Y_k متصل هستند) مورد استفاده قرار می‌گیرند. در مرحله تنظیم وزن‌ها نیز از ای عامل برای به روز کردن وزن‌های بین لایه خروجی لایه مخفی استفاده می‌شود. به همین ترتیب، عامل δ_j ($j = 1, \dots, p$) برای هر واحد مخفی Z_j محاسبه می‌شود. از δ_j فقط برای به روز کردن وزن‌های بین لایه مخفی و لایه ورودی استفاده می‌شود و لازم نیست خطای لایه مخفی را به لایه ورودی انتقال دهیم.

پس از اینکه تمامی عامل‌های δ معین شدند، وزن‌های شبکه برای تمام لایه‌ها به طور همزمان تنظیم می‌شوند. تنظیم وزن w_{jk} (وزن واحد مخفی j به واحد خروجی k) براساس عامل δ_k و فعالسازی واحد مخفی j (مقدار z_j) صورت می‌گیرد. تنظیم وزن v_{ij} (وزن واحد ورودی i به واحد مخفی j) براساس عامل δ_j و فعالسازی واحد ورودی i (صورت می‌گیرد).

-۳-۱-۷-۳ فهرست علائم و نام‌ها

علائم و نام‌هایی که در الگوریتم آموزش پس‌انتشار به کار می‌بریم، عبارتند از:

- $X = (x_1, \dots, x_i, \dots, x_n)$: بردار آموزش ورودی

- $t = (t_1, \dots, t_k, \dots, t_m)$: بردار هدف خروجی

- δ_k : بخشی از تنظیم وزن برای jk که مقدار آن با توجه به خطأ در واحد خروجی k (اختلاف خروجی شبکه و خروجی هدف) حساب می‌شود. همچنین این عاملی است که اطلاعات خطای رخداده در واحد k را به واحدهای مخفی وارد شده به واحد k منتشر می‌کند.

- δ_i : بخش تنظیم وزن تصحیح خطأ برای ij که بعد از پس‌انتشار اطلاعات خطأ از لایه خروجی به واحد مخفی j محاسبه می‌شود.

- α : نرخ یادگیری

- X_i : واحد ورودی i ، برای یک واحد ورودی، سیگنال ورودی و سیگنال خروجی آن واحد یکی بوده و برابر با x_i هستند.

- $.j$: بایاس در واحد مخفی j .

- Z_j : واحد مخفی j . ورودی واحد j با Z_j مشخص شود و برابر است با:

$$Z_in_j = v_{.j} + \sum_i x_i v_{ij}$$

سیگنال خروجی (فعالسازی) z_j ، Z_j نام دارد و داریم:

w : بایاس در واحد خروجی k .

واحد خروجی k . ورودی شبکه Y_k با y_{in_k} مشخص شود و برابر است با:

$$y_{in_k} = w_{\cdot k} + \sum_i z_j w_{jk}$$

سیگنال خروجی (فعال‌سازی) Y_k نشان داده می‌شود و داریم:

-۴-۱-۷-۳ تابع فعال‌سازی

برخلاف برخی از شبکه‌های دیگر، تابع فعال‌سازی مورد استفاده در شبکه‌های پس‌انتشار نمی‌تواند هر تابعی باشد و باید چند ویژگی مهم را داشته باشند. این تابع باید پیوسته، مشتق‌پذیر و به صورت یکنوا نزولی باشد. علاوه بر این، برای داشتن کارایی محاسباتی، مشتق این تابع به راحتی قابل محاسبه باشد. مقدار مشتق توابع فعال‌سازی مورد استفاده در اینجا را می‌توان بر حسب مقدار خود تابع بیان کرد. همچنین، انتظار می‌رود که تابع فعال‌سازی قابلیت اشباع^۱ را داشته باشد، یعنی به صورت مجانی به مقادیر بیشینه و کمینه خود نزدیک شود.

از متداول‌ترین توابع که شرایط بیان شده را دارند، می‌توان از توابع سیگموید دودویی و سیگموید دوقطبی با دامنه (۰-۱) نام برد [۴۱].

-۵-۱-۷-۳ الگوریتم آموزش

هر یک از توابع فعال‌سازی تعریف شده در بخش قبل را می‌توان در الگوریتم پس‌انتشار استاندارد به کار برد. شکل داده‌ها به ویژه مقادیر هدف عامل مهمی در انتخاب تابع فعال‌سازی است. به خاطر وجود رابطه ساده بین مقدار تابع و مشتق آن، نیاز به محاسبه بخش نمایی مشتق‌ها در مرحله پس-انتشار الگوریتم نیست. الگوریتم آموزش پس‌انتشار به صورت زیر است:

۱. به وزن‌ها مقدار اولیه می‌دهیم (مقادیر تصادفی کوچک را انتخاب می‌کنیم).
۲. تا زمانی که شرایط توقف برقرار نیست، مراحل ۳ تا ۱۰ را انجام می‌دهیم.

^۱ Saturate

۳. برای هر جفت آموزش (مقادیر ورودی و هدف)، مراحل ۴ تا ۹ را انجام می‌دهیم.

پیش خور:

۴. هر واحد ورودی ($X_i, i = 1, \dots, n$) سیگنال ورودی x_i را دریافت می‌کند و آن در تمام

واحدها در لایه بعدی (واحدهای مخفی) پخش می‌کند.

۵. هر واحد مخفی ($Z_j, j = 1, \dots, p$) سیگنال‌های ورودی وزن‌دار خود را جمع می‌بندند.

$$Z_j = \sum_i x_i v_{ij}$$

و از تابع فعال‌سازی خود برای محاسبه سیگنال خروجی استفاده می‌کند، یعنی: $(z_j = f(z_j - in_j))$

و این سیگنال را به تمام واحدهای لایه بعدی (واحدهای خروجی) می‌فرستد.

۶. هر واحد خروجی ($Y_k, k = 1, \dots, m$) سیگنال‌های وزن دار خود را جمع می‌بندد،

$$y_k = \sum_i z_j w_{jk}$$

و از تابع فعال‌سازی خود برای محاسبه سیگنال خروجی استفاده می‌کند، یعنی:

$$y_k = f(y_k - in_k)$$

پس انتشار خط:

۷. هر واحد خروجی ($Y_k, k = 1, \dots, m$) الگوی هدف متناظر با الگوی آموزش ورودی را دریافت

می‌کند و خط را محاسبه می‌کند:

$$\delta_k = (t_k - y_k) f'(y_k - in_k)$$

پارامتر تصحیح وزن را که بعداً در به روز کردن w_{jk} به کار می‌رود، محاسبه می‌کند:

$$\Delta w_{jk} = \alpha \delta_k z_j$$

پارامتر تصحیح بایاس را که بعداً در به روز کردن w_k به کار می‌رود، محاسبه می‌کند:

$$\Delta w_k = \alpha \delta_k$$

و δ_k (مقادیر دلتا) را به واحدهای لایه قبلی (لایه مخفی) می‌فرستد.

۸. هر واحد مخفی ($Z_j, j = 1, \dots, p$) ورودی‌های دلتای خود را جمع می‌بندد (ورودی‌های دریافتی از واحدهای لایه خروجی)،

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk}$$

و آن را در مشتق تابع فعال‌سازی خود ضرب می‌کند تا پارامتر مربوط به اطلاعات خطای را محاسبه می‌کند،

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

تصحیح وزن خود را که بعدا برای به روز کردن v_{ij} به کار می‌رود، محاسبه می‌کند،

$$\Delta v_{ij} = \alpha \delta_j x_i$$

و تصحیح بایاس خود را که بعدا برای به روز کردن $v_{\cdot j}$ به کار می‌رود، محاسبه می‌کند،

$$\Delta v_{\cdot j} = \alpha \delta_j$$

به روز کردن وزن‌ها و بایاس‌ها:

۹. هر واحد خروجی ($Y_k, k = 1, \dots, m$) وزن‌ها و بایاس‌های خود را به روز می‌کند ($p, \dots, 1$):

:)

$$w_{jk}^{(new)} = w_{jk}^{(old)} + \Delta w_{jk}$$

هر واحد مخفی ($Z_j, j = 1, \dots, p$) بایاس‌ها و وزن‌های خود را به روز می‌کند ($n, \dots, 1$):

$$v_{ij}^{(new)} = v_{ij}^{(old)} + \Delta v_{ij}$$

۱۰. شرایط توقف را بررسی می‌کنیم.

در پیاده‌سازی این الگوریتم، برای دلتاهای واحدهای خروجی و دلتاهای واحدهای مخفی باید از آرایه‌هایی جداگانه استفاده کرد. در اینجا یک دور معادل ارائه کل بردارهای آموزش است. معمولا برای آموزش شبکه عصبی پسانتشار دورهای زیادی لازم است. الگوریتم مذکور بعد از ارائه هر الگوی

آموزش، وزن‌ها را به روز می‌کند. در مقابل به روز کردن وزن‌ها به ازای هر الگوی ورودی، یک روش دیگر، به روز کردن وزن‌ها است که در آن به روز کردن وزن‌ها بعد از انجام شدن یک دور کامل یا ارائه تعدادی از الگوها صورت می‌گیرد.

مبنای ریاضی الگوریتم پساننتشار تکنیک بهینه‌سازی کاهش گرادیان^۱ است. بر مبنای این روش، گرادیان تابع جهتی را که تابع در آن سریع‌تر افزایش می‌یابد، را نشان می‌دهد و شیب با علامت منفی جهتی را نشان می‌دهد که در آن تابع سریع‌تر کاهش می‌یابد. در اینجا تابع مورد نظر تابع خطای شبکه می‌باشد و متغیرهای مورد نظر که مشتق بر حسب آنها گرفته می‌شود، وزن‌های شبکه هستند. براساس این اصل، روابط به روز کردن وزن‌های شبکه پساننتشار به دست می‌آیند [۴۱].

۳-۷-۱-۶- انتخاب وزن‌ها و بایاس‌های اولیه

انتخاب وزن‌های اولیه بر این امر که شبکه به حداقل خطای سراسری یا فقط محلی دست می‌یابد و اینکه با چه سرعتی به آن دست می‌یابد، تاثیر می‌گذارد. به روز کردن وزن بین دو واحد به مشتق فعال‌سازی واحد بعدی و فعال‌سازی واحد قبل بستگی دارد. به همین دلیل باید از انتخاب وزن‌های اولیه‌ای که احتمال دارد فعال‌سازی‌ها یا مشتق فعال‌سازی‌ها را صفر کنند، خودداری کنیم. مقادیر وزن‌های اولیه نباید زیاد بزرگ باشند، چون ممکن است باعث شوند سیگنال‌های ورودی به واحدهای مخفی یا واحدهای خروجی در ناحیه اشباع قرار بگیرند که در آن مشتق تابع سیگموید مقدار کوچکی دارد. از طرف دیگر اگر وزن‌های اولیه بسیار کوچک انتخاب شوند سیگنال‌های ورودی به واحدهای مخفی یا واحد خروجی به صفر نزدیک خواهد بود که موجب کند شدن یادگیری می‌شود. بازه متداول برای مقادیر تصادفی وزن‌ها و بایاس‌ها بین -0.5 و 0.5 یا بین -1 و 1 است. این مقادیر می‌توانند مثبت یا منفی باشند، زیرا وزن‌های نهایی بعد از آموزش ممکن است هر علامتی داشته باشند [۴۱].

^۱ Gradient Descent

چون انگیزه اصلی استفاده از شبکه پس انتشار دستیابی به تعادل بین دادن پاسخ صحیح به الگوهای آموزش داده شده به شبکه و تولید پاسخ مناسب به الگوهای جدید است (تعادل بین یادگیری الگوها و تعمیم)، ادامه آموزش شبکه زمانی که مقدار مربعات خطأ واقعاً حداقل شده باشد، الزاماً مفید نمی‌باشد. به همین منظور پیشنهاد شده است که از دو مجموعه داده مجزا برای آموزش – آزمون الگوها، تغییر وزن‌ها در شبکه بر اساس داده آموزش صورت می‌گیرد و در بازه‌هایی در طول آموزش، خطای شبکه برای داده‌های آموزش – آزمون محاسبه می‌شود. بر این اساس، تا زمانی که مقدار خطای داده‌های آموزش – آزمون در حین آموزش کاهش می‌یابد، آموزش ادامه خواهد یافت. زمانی که خطای شبکه شروع به افزایش می‌کند، شبکه مشخصاً شروع به حفظ کردن الگوهای آموزش می‌کند و قابلیت تعمیم‌دهی خود را رفته رفته از دست می‌دهد. در این نقطه آموزش پایان می‌یابد [۴۱].

فصل چهارم

پیش‌بینی کوتاه مدت بار با

در نظر گرفتن روزهای خاص

۱-۴ - مقدمه

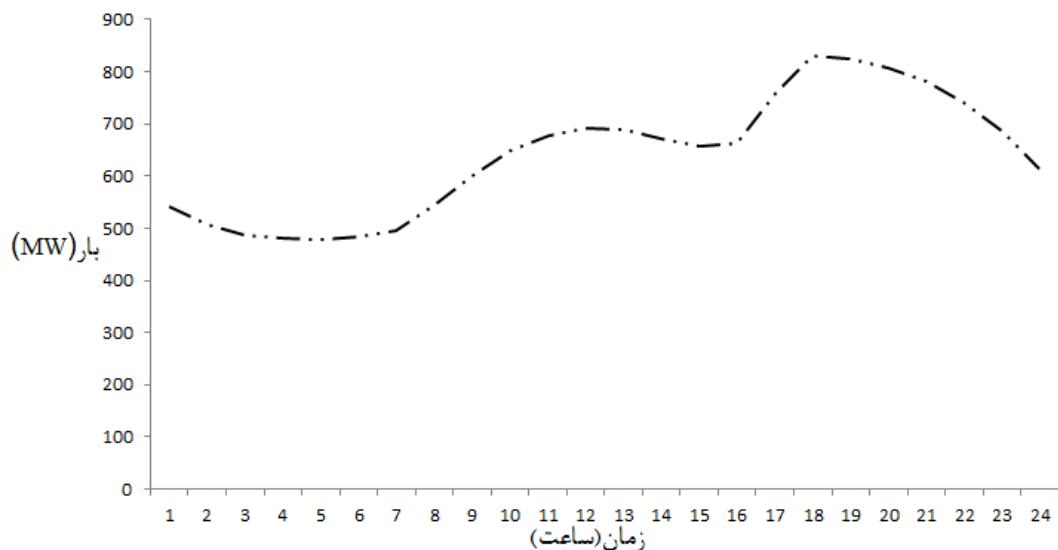
برای شبکه‌های عصبی با یادگیری تحت نظارت، به طور وسیع از شبکه پیش‌خور چند لایه استفاده می‌شود و پیشرفت‌های زیادی نیز در این زمینه انجام شده است. یکی از این پیشرفت‌ها روش تفکیک است که به دلیل اختلاف موجود در شکل بار فصلی و روزانه مطرح شده است. در روش تفکیک شبکه به چندین زیر شبکه تقسیم می‌شود. به عنوان مثال شبکه را به سه گروه شنبه، یک‌شنبه، و روزهای هفته تقسیم می‌کنند، یا شبکه به ازای هر روز هفته به هفت شبکه عصبی مصنوعی که هر یک دارای ۲۴ خروجی است، تقسیم می‌شود [۴۰]. تقسیم‌بندی ورودی بر مبنای فصول راه دیگری برای تفکیک است. به عنوان مثال در [۴۳] از دو مدل، یکی برای زمستان و دیگری برای تابستان استفاده شده است. در این پایان نامه برای پیش‌بینی روز بعد از ۲۴ شبکه که بیانگر ساعت‌های روز است استفاده می‌شود.

۲-۴ - روش پیشنهادی

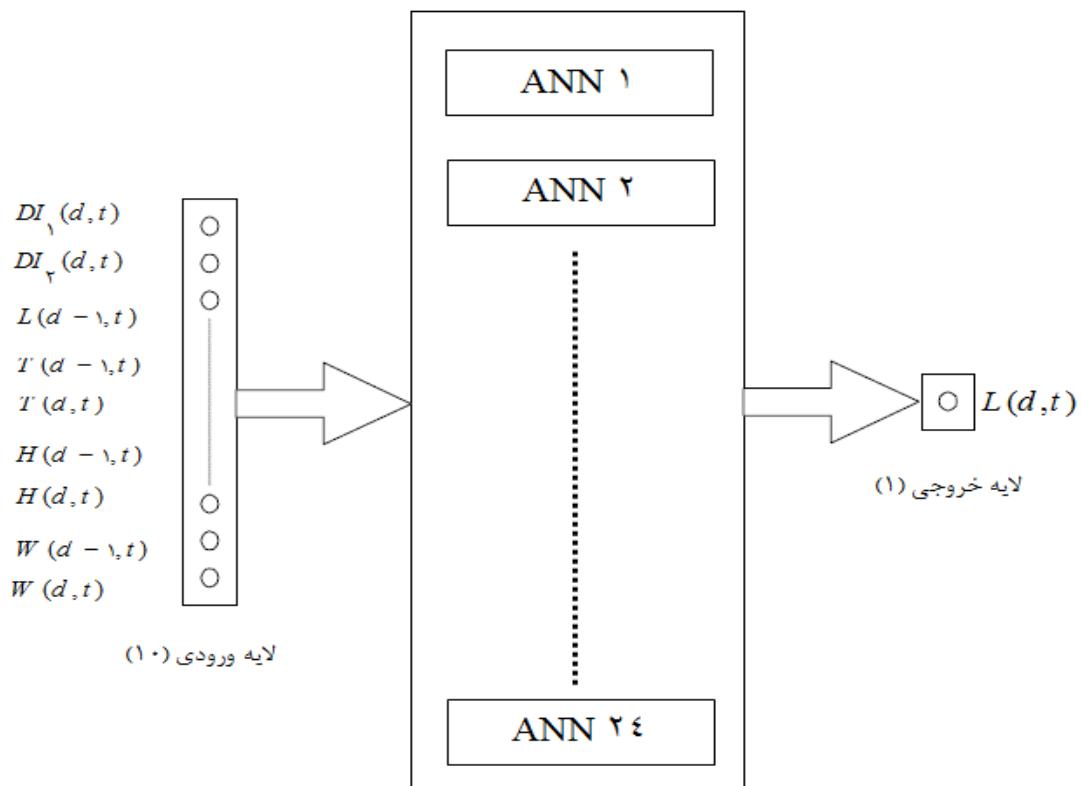
شکل (۱-۴) بار مصرفی ساعتی در روز سه‌شنبه ۱۰ آبان سال ۱۳۸۸ شهرستان مشهد را نمایش می‌دهد. همان‌طور که مشاهده می‌شود، مقدار مصرف بار در ساعت‌های مختلف شبانه روز با هم متفاوت است. در این صورت به نظر می‌رسد که بهتر است با استفاده از نمونه‌های مختلف شبکه عصبی مصنوعی بین تک‌تک ساعت‌ها تفاوت قائل شد. بنابراین آموزش ساده‌تر شده و بخت بیشتری برای داشتن نتایج بهتر وجود دارد.

برای رسیدن به این منظور در این مدل از روش تفکیک ساعتی برای پیش‌بینی بار کوتاه مدت بار استفاده می‌شود و ۲۴ شبکه عصبی مصنوعی برای پیش‌بینی بار ۲۴ ساعت آینده به کار بردگ می‌شود. نمودار بلوکی شبکه ساعتی در شکل (۲-۴) نمایش داده شده است.

در فرآیند آموزش به هر شبکه عصبی فقط داده‌های آن ساعت داده می‌شود. هر ۲۴ شبکه عصبی ساعتی، دارای معما ری یکسان هستند که همان شبکه عصبی پیش خور دو لایه می‌باشد.



شکل ۴-۱- بار مصرفی ساعتی در روز سه شنبه ۱۰ آبان سال ۱۳۸۸ شهرستان مشهد



شکل ۴-۲- نمودار بلوکی شبکه ساعتی

-۱-۲-۴

معماری شبکه عصبی مصنوعی برای مدل پیشنهادی

-۱-۱-۲-۴

انتخاب ورودی‌های شبکه عصبی

یکی از کلیدهای معماری خوب برای شبکه‌های عصبی مصنوعی، انتخاب ورودی‌های مناسب است. در مورد پیش‌بینی کوتاه مدت بار، این ورودی‌ها می‌توانند به زمان، بار الکتریکی و اطلاعات آب و هوازی تقسیم شوند. هیچ نوع مقررات کلی در طراحی شبکه‌های عصبی مصنوعی برای پیش‌بینی بار کوتاه مدت وجود ندارد. استفاده از ورودی‌هایی که تاثیر کمی بر پیش‌بینی کوتاه مدت بار دارند باعث عملکرد نامناسب و افزایش زمان آموزش شبکه شده و عدم استفاده از عوامل موثر باعث کاهش دقت مدل می‌شود. ترکیب ورودی برای پیش‌بینی بار کوتاه مدت در روز (d) و ساعت (t) که با $L(d,t)$ نشان داده شده، در معادله (۱-۴) آورده شده است:

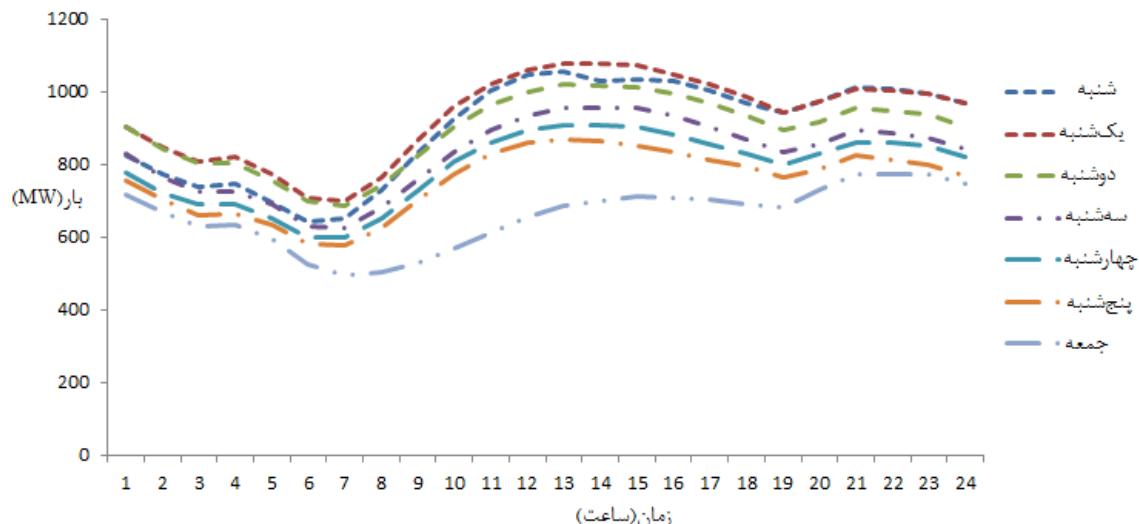
$$L(d,t) = f [DI_1(d,t), DI_2(d,t), L(d-1,t), T(d-1,t), T(d,t), H(d-1,t), H(d,t), W(d-1,t), W(d,t)] \quad (1-4)$$

در ادامه پارامترهای ورودی استفاده شده در مدل پیشنهادی شرح داده می‌شوند:

- کد روز ۱، روز پیش‌بینی (d) در همان ساعت (t): ($DI_1(d,t)$)

این کد برای تعیین روز پیش‌بینی به کار می‌رود. همان‌طور که در شکل (۲-۴) دیده می‌شود، هر روز خاص هفته منحنی بار خاص خود را دارد، معمولاً میزان مصرف بار در روزهای آغازین هفته در مقایسه با روزهای دیگر بیشتر است و در اواخر هفته به خصوص روز جمعه به دلیل تعطیلی مدارس، ادارات و بعضی از واحدهای تجاری و صنعتی، بسیار کمتر از روزهای دیگر است. بنابراین بهتر است که ما تک تک روزهای هفته را برای پیش‌بینی بار آن روز از هفته، از هم جدا کنیم. در اینجا برای تعیین روز پیش‌بینی، یک نرون به کار می‌رود و ایام هفته با اعداد ۱ تا ۷ برای این نرون مشخص می‌شوند: ۱ برای شنبه، ۲ برای یکشنبه، ۳ برای دوشنبه و الی آخر. می‌توان با استفاده از هفت نرون،

روز هفته را مشخص کرد، اما این تنها به معنی افزایش تعداد نرون‌ها و کند شدن فرآیند یادگیری است.



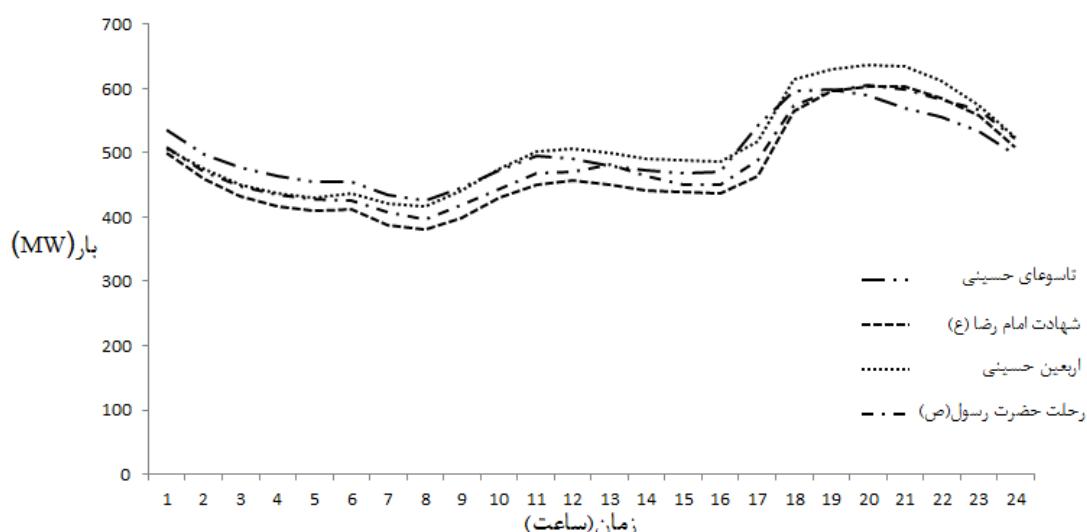
شکل ۳-۴- منحنی مصرف روزهای مختلف هفته

- کد روز ۲، روز پیش‌بینی (d) در همان ساعت (t): $(DI_2(d,t))$
- علاوه بر انتخاب روزهای هفته ما باید به نوع روزهای هفته و تعطیلات خاص نیز توجه ویژه‌ای داشته باشیم. یکی از موثرترین عوامل در پیش‌بینی بار کوتاه مدت شرایط تقویمی می‌باشد. بررسی های انجام شده نشان می‌دهد که پیش‌بینی نیاز مصرف روزهای خاص مانند عاشورا، تاسوعاً، شهادت حضرت علی، عید فطر و ... بسیار مشکل است که دلایل آن را می‌توان به صورت زیر خلاصه نمود:

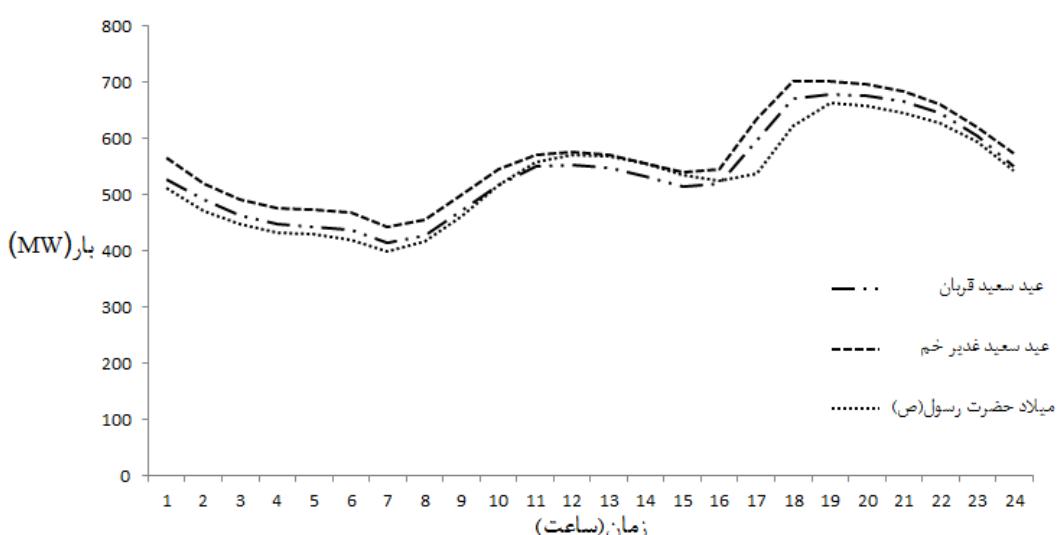
 - ۱- حرکت این روزها در ماهها و روزهای سال: به علت آن که یک سال قمری ۳۵۵ روز و یک سال شمسی ۳۶۵ روز می‌باشد، یک روز از ماه قمری در سالهای مختلف جابجا می‌شود. این جابجایی باعث می‌شود که اطلاعات نیاز مصرف سال گذشته و چند سال گذشته برای سال جاری اعتبار چندانی نداشته باشد و پیش‌بینی نیاز مصرف را با مشکل مواجه سازد.
 - ۲- وابسته بودن مصرف به روزهای هفتگی: همچنان که در توضیح داده خواهد شد منحنی مصرف روزهای مختلف متفاوت است. علاوه بر این روزهای خاص که بیشتر جزء ماههای قمری

می باشند در سالهای مختلف جابجا می شود، بنابراین یک روز خاص در سالهای مختلف در روزهای مختلف هفته قرار می گیرد و هر سال منحنی مصرف آن تغییر می کند و بنابراین داده های سالهای گذشته برای پیش بینی نیاز مصرف معتبر نمی باشد.

میزان بار مصرفی برخی از روزهای عزاداری و شهادت های قمری شهرستان مشهد در سال ۱۳۸۹ در شکل (۴-۴) و همچنین بعضی از اعیاد و ولادت های قمری در شکل (۴-۵) نمایش داده شده است.



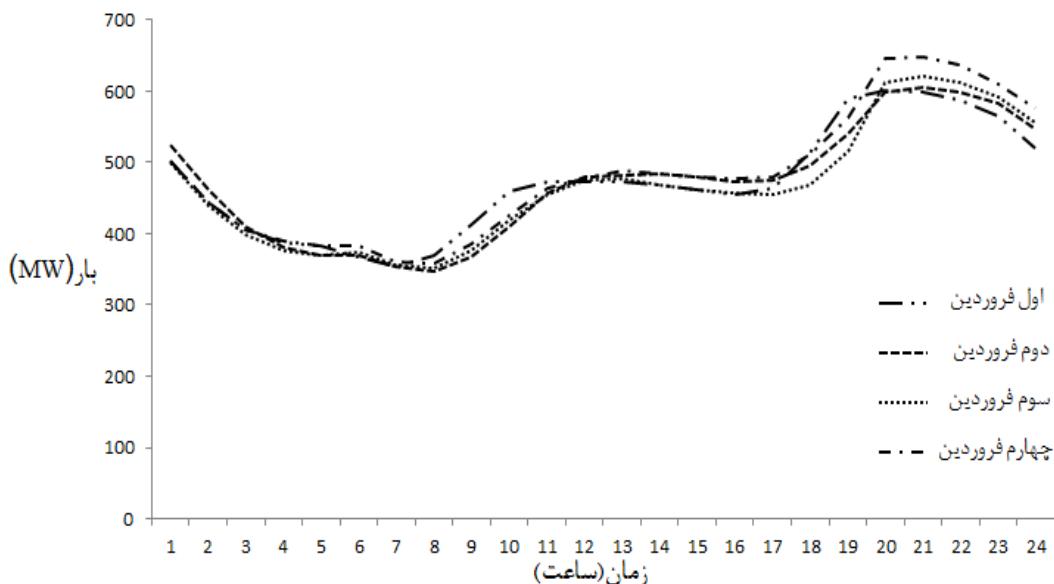
شکل ۴-۴- میزان بار مصرفی شهرستان مشهد در برخی از شهادت ها و عزاداری های قمری در سال ۱۳۸۹



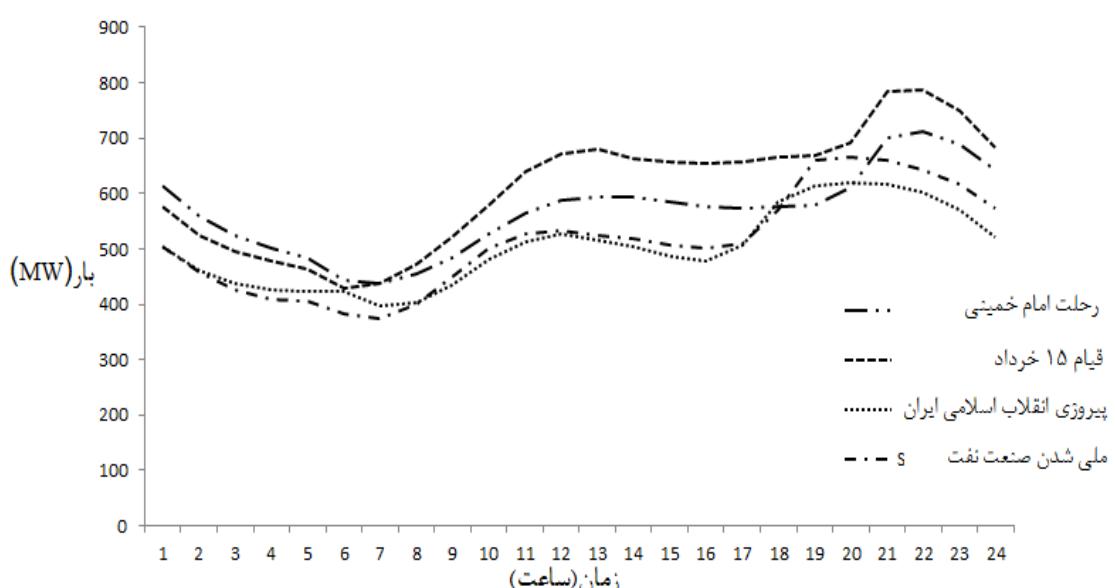
شکل ۴-۵- میزان بار مصرفی شهرستان مشهد در برخی از اعیاد و ولادت های قمری در سال ۱۳۸۹

با بررسی دقیق رفتار منحنی بار روزهای تعطیل قمری مشخص شد که مصرف بار در ایام عزاداری و شهادت‌ها تفاوت مشهودی با اعیاد و ولادت‌های قمری دارد که این نکته در شکل‌های (۴-۵) و (۴-۶) قابل مشاهده است. بنابراین می‌توان این مناسبتها را در دو دسته جداگانه تقسیم بندی نمود.

منحنی روزانه میزان مصرف بار سال ۱۳۸۹ شهرستان مشهد در تعطیلات نوروزی و تعطیلات شمسی دیگر در شکل‌های (۶-۷) و (۷-۸) نمایش داده شده است.



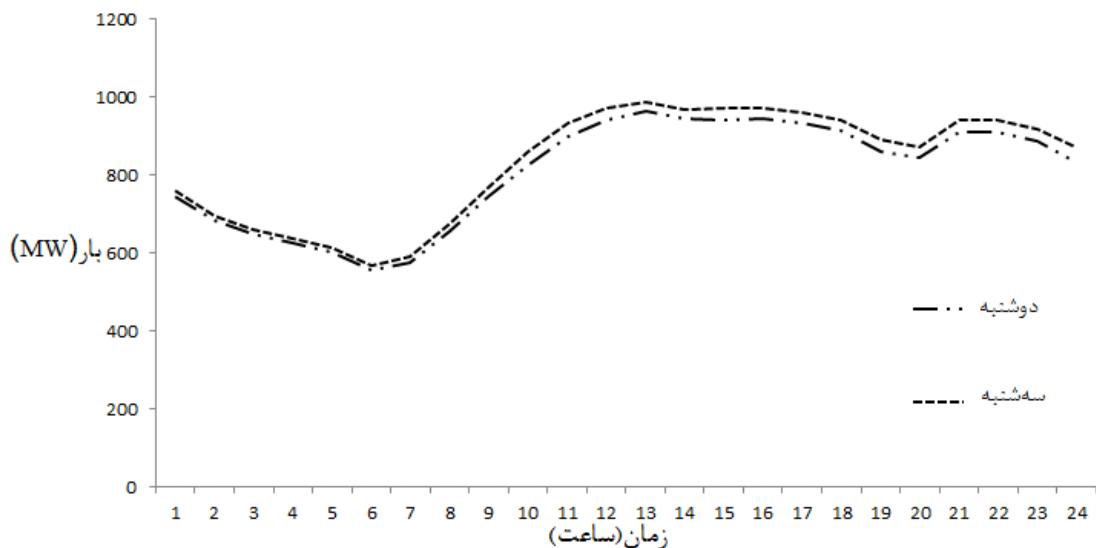
شکل ۴-۶- میزان بار مصرفی شهرستان مشهد در تعطیلات نوروزی سال ۱۳۸۹



شکل ۴-۷- میزان بار مصرفی شهرستان مشهد در تعطیلات شمسی سال ۱۳۸۹

همان طور که مشاهده می‌شود مصرف بار در تعطیلات نوروزی تفاوت قابل مشاهده‌ای با دیگر تعطیلات شمسی دارد. به همین خاطر ما تعطیلات شمسی را نیز به دو دسته جداگانه تقسیم بندی می‌کنیم. با توجه به موارد ذکر شده، در این مدل ما روزهای سال را به روزهای عادی، روزهای قبل از تعطیل، روزهای بعد از تعطیل، روزهای مابین تعطیلات، تعطیلات نوروزی، تعطیلات شمسی، اعیاد و ولادت های قمری، شهادتها و مناسبتهای عزاداری تقسیم‌بندی می‌کنیم.

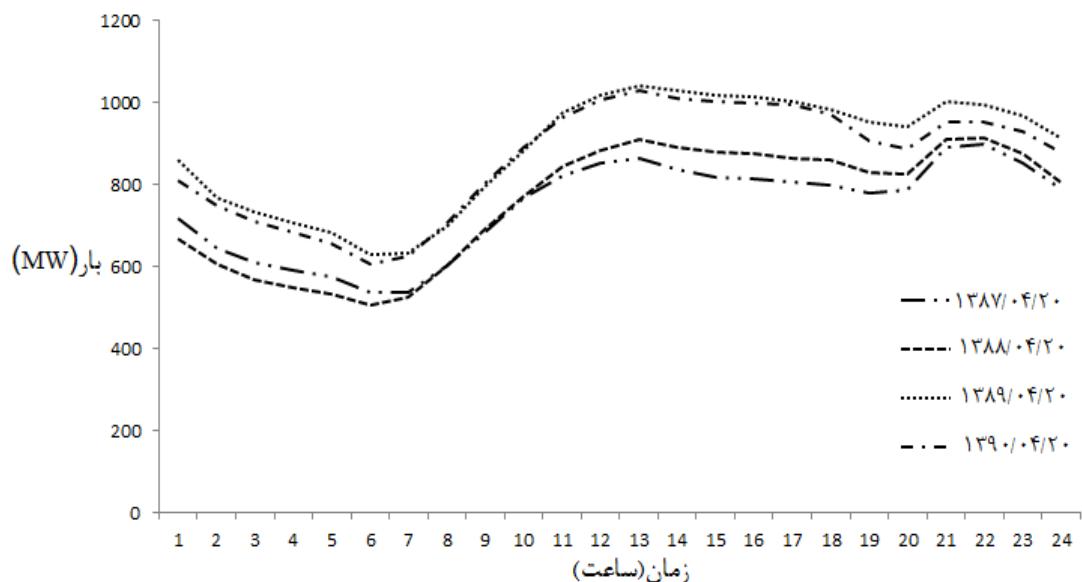
- مصرف بار روز قبل از پیش‌بینی ($d-1,t$) در همان ساعت (t):
 میزان مصرف بار روز قبل در همان ساعت تاثیر بهسزایی در میزان بار مصرفی ساعت پیش‌بینی دارد.
 همان طور که در شکل (۴-۸) مشاهده می‌شود، بار روز پیش‌بینی رفتار کاملاً مشابهی به منحنی بار روز قبل خود دارد و در بسیاری از مقالات از این ورودی به عنوان موثرترین عامل بر پیش‌بینی کوتاه‌مدت بار نام برده می‌شود.



شکل ۴-۸- منحنی میزان بار ساعتی مصرفی در روزهای ۱۳/۰۴/۹۰، ۱۴/۰۴/۹۰ و ۱۵/۰۴/۹۰ شهرستان مشهد

در بعضی از موارد از میزان مصرف در روز مشابه از هفته قبل و همچنین میزان مصرف روز مشابه از سال قبل از پیش‌بینی به عنوان یکی از پارامترهای ورودی استفاده می‌شود. این پارامترها ممکن است اندکی دقت پیش‌بینی با روزهای عادی را بهبود ببخشد ولی باعث افزایش زیاد خطای پیش‌بینی بار

روزهای خاص می‌شوند. در شکل (۹-۴) میزان مصرف بار یک روز مشابه در چهار سال مختلف نشان داده شده است.



شکل ۴-۹- منحنی میزان بار ساعتی مصرفی روز ۲۰ تیر در چهار سال مختلف شهرستان مشهد

عوامل آب و هوایی از موثرترین عوامل تاثیرگذار در مصرف انرژی می‌باشند. شکل (۹-۴) میزان مصرف

بار ساعتی چهار روز مختلف را در فصول مختلف سال نشان می‌دهد. مهم‌ترین عامل تفاوت منحنی بار

ساعتی این روزها، شرایط آب و هوایی خاص مربوط به هر فصل می‌باشد. درجه حرارت، میزان رطوبت

و سرعت باد از مهم‌ترین عوامل آب و هوایی موثر بر پیش‌بینی بار کوتاه مدت می‌باشند.

- درجه حرارت روز قبل از پیش‌بینی ($T(d-1,t)$) در همان ساعت (t):

- پیش‌بینی درجه حرارت روز پیش‌بینی (d) در همان ساعت (t):

- میزان رطوبت روز قبل از پیش‌بینی ($H(d-1,t)$) در همان ساعت (t):

- پیش‌بینی میزان رطوبت روز پیش‌بینی (d) در همان ساعت (t):

- میزان سرعت باد روز قبل از پیش‌بینی ($W(d-1,t)$) در همان ساعت (t):

- پیش‌بینی میزان سرعت باد روز پیش‌بینی (d) در همان ساعت (t):

-۲-۱-۲-۴ لایه نهان شبکه عصبی

از آنجایی که روش عمومی برای تعیین تعداد صحیح نرون‌ها در لایه نهان وجود ندارد، تعداد آنها را در لایه نهان باید به صورت ابتکاری (تجربی) تعیین نمود. اگر تعداد آنها خیلی کم باشد، شبکه نمی‌تواند ارتباط پیچیده بین ورودی و خروجی را پیدا کند و محتمل است در طی دوره آموزش در همگرایی با اشکال مواجه شود. اگر تعداد آنها خیلی زیاد باشد، فرآیند آموزش بیشتر طول کشیده و می‌تواند به توانایی شبکه عصبی مصنوعی صدمه بزند.

تعداد نرون‌های لایه نهان، در کاربردهای گوناگون می‌تواند تغییر کند و معمولاً وابسته به اندازه مجموعه آموزش و تعداد متغیرهای ورودی است. چند قاعده ابتکاری در زیر آمده است [۴۰]:

- تعداد نورون‌های لایه نهان برابر با تعداد نورون‌لایه ورودی به اضافه یک است.
- تعداد نورون‌های لایه نهان برابر با تعداد نورون‌های لایه ورودی به اضافه تعداد نورون‌لایه خروجی است.
- تعداد نورون‌های لایه نهان برابر با مجموع تعداد نورون‌های لایه ورودی و تعداد نورون‌لایه خروجی تقسیم بر دو است.

در عمل، بهتر است قبل از تعیین مناسب نورون‌ها چند آزمون انجام داد. پس از انجام چند آزمون برای لایه مخفی این مدل، ۱۰ نورون انتخاب شد.

-۳-۱-۲-۴ لایه خروجی شبکه عصبی

برای لایه خروجی انتخاب و تنظیم تعداد نورون‌ها در مقایسه با لایه‌های ورودی و نهان، کاری نسبتاً ساده است و بسته به نوع مسئله انتخاب می‌شود. برای این مسئله برای هر شبکه عصبی یک نورون به عنوان بار ساعت پیش‌بینی استفاده می‌شود.

نرمال‌سازی داده‌ها -۲-۲-۴

یکی از مواردی که در دقت پیش‌بینی بار مصرفی در مسئله بسیار سودمند می‌باشد مسئله مقیاس-بندی داده‌ها می‌باشد، که در اینجا اطلاعات ورودی به مقیاس بین (۱,۱-) تبدیل شده است که آموزش شبکه را بسیار آسان‌تر می‌سازد. از طرفی عدم نرمال‌سازی داده‌ها ممکن است باعث شود که که داده‌هایی با مقادیر بالا (بار الکتریکی) اثر داده‌های با مقادیر پایین (داده‌های آب و هوا) را از بین برده و بر آنها تاثیر منفی بگزارند. جهت نرمال‌سازی داده‌ها از رابطه (۱-۴) استفاده شده است.

$$P_n = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \times 2 - 1 \quad (1-4)$$

به‌طوریکه P_{\min} ، P_{\max} ، P و P_n به ترتیب مقادیر مقیاس‌بندی شده، مقادیر واقعی، بیشترین مقدار و کمترین مقدار می‌باشند. مقادیر پیش‌بینی شده نهایی هم می‌تواند از رابطه (۲-۴) به مقادیر واقعی برگردانده شوند.

$$P = (P_n + 1) \frac{P_{\max} - P_{\min}}{2} + P_{\min} \quad (2-4)$$

ساختار شبکه عصبی -۳-۲-۴

ساختار شبکه عصبی مورد استفاده به شرح زیر است:

۱- شبکه پیشخور دو لایه با تعداد ۹ نورون در لایه ورودی، ۱۰ نورون در لایه مخفی و ۱ نورون در لایه خروجی است.

۲- روش آموزش لونبرگ-مارکوارت که یک روش ترکیبی مرتبه دوم می‌باشد. در این روش سعی بر تقریب زدن ماتریس هسیان است. با توجه به این فرض که تابع خطا (تفاوت بین مقادیر خروجی واقعی و پاسخ‌های شبکه) نوعی مجموع مربعات است، اصلاح S به صورت زیر

قابل نوشتن است:

$$s_{i+1} = s_i - \left[J^T J + \mu I \right]^{-1} J^T e \quad (3-4)$$

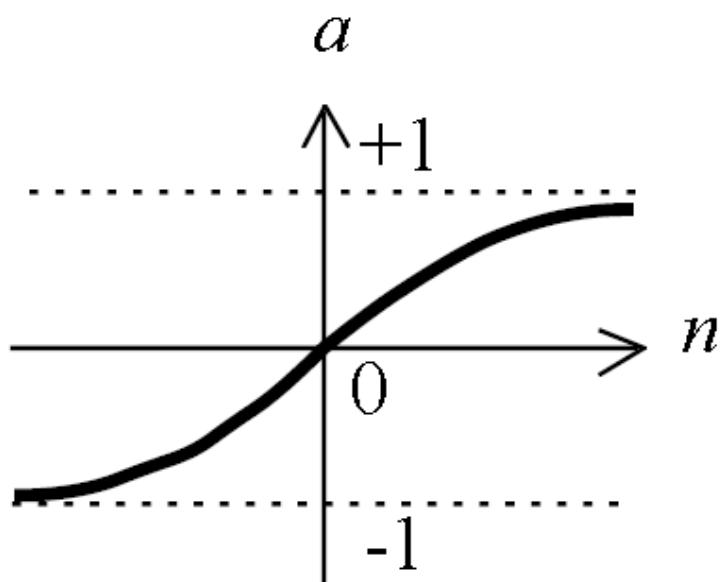
در رابطه بالا، s_i مسیر نزولی الگوریتم جهت یافتن بردار وزن‌های بهبود یافته شبکه در مرحله آموزش با هدف مینیمم کردن خطاست. J ماتریس ژاکوبین بوده و e بردار مقادیر خطای شبکه است. پارامتر تعیین کننده در این شبکه μ ، یک اسکالر کنترلی برای رفتار الگوریتم است. اگر $\mu = 0$ باشد، الگوریتم مانند روش نیوتن عمل می‌کند و هر چه μ بزرگ‌تر شود، شباهت روش به الگوریتم نزول گردیان افزایش یابد. چرا که داریم:

$$H = J^T J \quad (4-4)$$

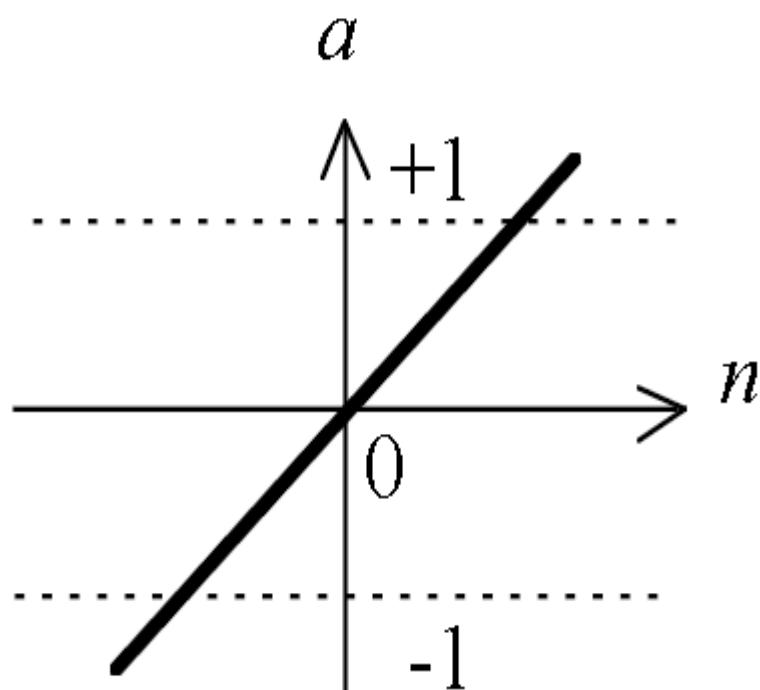
$$g = J^T e \quad (5-4)$$

در معادله بالا، H ماتریس هسیان در روش نیوتن و g گردیان است. در تکرارهای اول مقدار بزرگ برای پارامتر μ مطلوب است و هنگامی که الگوریتم به خطای مینیمم نزدیک می‌شود، روش نیوتن سریع‌تر و صریح‌تر عمل می‌کند. بنابراین μ در طول پروسه آموزش تغییر داده می‌شود. بعد از هر تکرار موفق μ کاهش یافته و بعد از هر تکرار ناموفق μ افزایش می‌یابد.

۳- تابع فعالیت در لایه مخفی، تانژانت سیگموید و در لایه خروجی، خطی است. منحنی مشخصه این توابع در شکل‌های (۱-۳) و (۴-۱) نشان داده شده است. خروجی تابع تانژانت سیگموید با توجه به مثبت یا منفی بودن ورودی اعمال شده، بین ۱ تا -۱ خواهد بود. خروجی تابع خطی نیز از ورودی اعمال شده تبعیت خواهد داشت. اگر نرون‌های لایه آخر شبکه عصبی از توابع انتقال سیگموید استفاده کنند، خروجی‌های شبکه به یک گستره کوچک محدود می‌شوند. ولی اگر در لایه آخر شبکه از توابع خطی استفاده شود، خروجی‌های شبکه می‌توانند هر مقداری را اختیار کنند.



شکل ۴-۱۰- تابع انتقال تانژانت سیگموید [۴۵]



شکل ۴-۱۰- تابع انتقال خطی [۴۵]

برای آموزش شبکه عصبی از داده‌های سه سال ۸۶، ۸۷ و ۸۹ و برای تست آن از داده‌ای سال ۹۰ شهرستان مشهد استفاده شده است.

۴-۲-۴ معیار تفکیک خطاهای

برای تفکیک خطاهای در صد خطای مطلق^۱ (APE) و میانگین درصد خطای مطلق^۲ (MAPE) که به صورت زیر تعریف شده‌اند، مورد استفاده قرار می‌گیرد [۴۰].

$$APE = \frac{|Load_{forecast} - Load_{actual}|}{Load_{actual}} \times 100\% \quad (6-4)$$

$$MAPE = \frac{1}{N_h} \sum_{N_h} APE \quad (7-4)$$

در رابطه بالا، $Load_{forecast}$ بار پیش‌بینی شده، $Load_{actual}$ بار حقيقی و N_h تعداد ساعات در دوره پیش‌بینی است.

۵-۲-۴ بررسی و تحلیل نتایج

آموزش شبکه عصبی حدود ۷۳۰ ثانیه به طول انجامید. میانگین درصد خطای سالیانه ۴۵٪/۲ می‌باشد که این مقدار خطا قابل قبول است. نتایج پیش‌بینی برای دو ماه مرداد و بهمن در سال ۱۳۹۰ در جداول (۱-۴) و (۲-۴) آورده شده است.

همان طور که مشاهده می‌شود نتایج حاصله از این مدل به جز مواردی خاص مطلوب است. بالاترین دمای این سال با میانگین ۲۱/۳۳ درجه سانتی‌گراد و ماکزیمم دمای ۳۹ درجه سانتی‌گراد در ساعت ۱۱ روز جمعه مورخ ۱۴ مرداد روی می‌دهد. در این روز میانگین در صد خطای مطلق برای این مدل پیشنهادی برابر ۸۸٪/۲ است، که این نشان‌دهنده این است که مدل پیشنهادی توانایی پیش‌بینی دقیق شرایط نهایی جوی را دارد. منحنی میزان بار واقعی و بار پیش‌بینی شده در این روز در شکل (۱۲-۴) نمایش داده شده است.

^۱ Absolute Percentage Error

^۲ Mean Absolute Percentage Error

جدول ۴-۱- میزان درصد خطای مطلق و میانگین درصد خطای مطلق در مرداد ماه سال ۱۳۹۰

ساعت تاریخ	درصد خطای مطلق (APE)											
	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
۹۰/۰۵/۱	۱/۰۴	۲/۷۳	۰/۹۷	۵/۳۴	۶/۷۲	۳/۳۴	۱/۷۳	۰/۸۰	۰/۴۴	۲/۰۷	۱/۶۶	۲/۳۳
۹۰/۰۵/۲	۰/۷۹	۱/۸۳	۵/۶۶	۰/۵۶	۴/۳۰	۰/۵۶	۱/۶۹	۱/۲۵	۰/۸۸	۰/۰۹	۰/۰۶	۰/۷۲
۹۰/۰۵/۳	۲/۹۶	۳/۵۷	۲/۵۵	۴/۳۳	۲/۰۸	۱/۹۳	۱/۳۷	۰/۷۸	۰/۴۸	۱/۴۵	۰/۸۱	۲/۱۲
۹۰/۰۵/۴	۰/۶۰	۰/۶۸	۱/۴۴	۳/۶۳	۳/۸۷	۱/۷۹	۰/۷۳	۳/۰۲	۰/۴۱	۰/۰۷	۰/۳۷	۱/۴۵
۹۰/۰۵/۵	۳/۲۵	۲/۹۸	۱/۴۳	۱/۲۳	۰/۵۲	۰/۳۳	۰/۶۷	۰/۷۳	۱/۰۸	۰/۵۴	۰/۶۶	۰/۴۸
۹۰/۰۵/۶	۵/۶۴	۴/۱۱	۳/۲۸	۱/۰۳	۰/۹۳	۰/۶۶	۳/۴۲	۳/۶۳	۲/۲۷	۱/۷۴	۳/۱۸	۱/۶۷
۹۰/۰۵/۷	۲/۲۸	۰/۵۲	۱/۳۳	۰/۰۰	۱/۱۱	۱/۴۰	۰/۲۲	۱/۹۵	۱/۶۳	۳/۲۶	۱/۶۸	۳/۴۰
۹۰/۰۵/۸	۱/۷۰	۰/۶۷	۵/۴۲	۰/۶۶	۱/۳۳	۰/۴۳	۰/۲۵	۱/۰۵	۰/۱۲	۶/۹۳	۵/۴۷	۶/۶۵
۹۰/۰۵/۹	۰/۶۱	۲/۵۸	۵/۱۳	۱/۷۸	۰/۷۵	۳/۳۹	۲/۱۳	۳/۴۵	۳/۵۲	۱/۴۴	۳/۰۶	۲/۸۳
۹۰/۰۵/۱۰	۳/۴۳	۳/۰۷	۴/۸۳	۳/۵۱	۰/۹۱	۰/۲۸	۱/۳۴	۰/۱۴	۰/۵۷	۰/۸۵	۱/۷۱	۴/۶۰
۹۰/۰۵/۱۱	۳/۴۶	۳/۲۷	۳/۸۱	۷/۸۹	۱/۲۹	۲/۸۶	۱/۷۸	۱/۲۰	۱/۸۹	۳/۰۵	۳/۵۹	۴/۳۶
۹۰/۰۵/۱۲	۱/۰۵	۰/۹۲	۰/۹۱	۱۰/۱۱	۲/۳۴	۱/۱۸	۴/۰۲	۵/۱۱	۱/۱۹	۵/۴۲	۳/۹۸	۵/۹۳
۹۰/۰۵/۱۳	۱/۱۳	۲/۸۴	۲/۴۴	۱۲/۹۳	۳/۱۱	۱/۷۳	۰/۶۴	۴/۰۲	۲/۲۶	۵/۶۰	۱/۸۳	۳/۴۶
۹۰/۰۵/۱۴	۸/۰۴	۰/۵۹	۱/۲۵	۱۴/۲۸	۰/۰۹	۳/۴۶	۱/۹۶	۱/۸۵	۱/۳۰	۸/۰۴	۴/۵۸	۰/۰۱
۹۰/۰۵/۱۵	۲/۲۲	۱/۷۰	۰/۳۲	۲/۴۸	۳/۹۳	۱/۲۴	۰/۶۸	۲/۱۲	۵/۸۸	۱/۹۲	۳/۱۸	۱/۰۵
۹۰/۰۵/۱۶	۱/۴۵	۱/۷۳	۸/۲۹	۸/۳۲	۷/۹۴	۳/۵۰	۳/۵۳	۰/۴۱	۱/۱۸	۱/۸۳	۱/۹۳	۲/۰۲
۹۰/۰۵/۱۷	۳/۰۴	۰/۳۰	۶/۴۶	۱۱/۴۶	۵/۲۳	۱/۶۱	۱/۸۲	۰/۴۸	۰/۴۲	۱/۹۴	۱/۲۸	۰/۷۸
۹۰/۰۵/۱۸	۰/۲۱	۲/۸۲	۰/۷۰	۷/۹۲	۰/۹۲	۳/۱۹	۲/۵۶	۱/۷۱	۳/۸۶	۴/۲۲	۳/۴۶	۳/۰۰
۹۰/۰۵/۱۹	۱/۷۲	۲/۲۱	۰/۸۴	۲/۲۶	۰/۰۴	۱/۷۳	۰/۰۴	۰/۱۶	۰/۱۸	۲/۰۸	۳/۰۷	۲/۳۷
۹۰/۰۵/۲۰	۰/۶۸	۰/۸۱	۲/۰۲	۰/۴۴	۰/۲۱	۲/۰۷	۱/۰۱	۱/۴۲	۰/۲۸	۰/۵۷	۱/۴۹	۰/۵۲
۹۰/۰۵/۲۱	۱/۵۱	۲/۰۴	۱/۴۹	۰/۸۲	۳/۲۹	۵/۲۷	۳/۹۱	۰/۴۰	۳/۸۹	۲/۸۹	۴/۳۳	۱/۶۳
۹۰/۰۵/۲۲	۳/۱۰	۴/۰۲	۱/۷۷	۰/۱۷	۱/۰۲	۲/۸۰	۳/۲۳	۱/۳۴	۱/۵۱	۰/۵۰	۲/۸۱	۱/۹۹
۹۰/۰۵/۲۳	۱/۵۲	۵/۰۱	۹/۰۰	۰/۷۰	۳/۵۷	۰/۰۰	۲/۵۸	۱/۵۳	۱/۷۱	۱/۲۰	۱/۱۸	۳/۸۸
۹۰/۰۵/۲۴	۲/۳۳	۱/۷۶	۳/۶۱	۰/۵۹	۱/۱۵	۰/۷۶	۱/۷۴	۰/۷۵	۰/۶۸	۲/۴۸	۲/۲۶	۴/۰۴
۹۰/۰۵/۲۵	۴/۱۳	۴/۰۳	۳/۹۶	۳/۱۱	۲/۱۱	۱/۷۹	۱/۲۶	۰/۳۸	۱/۵۹	۲/۰۳	۲/۷۹	۳/۰۶
۹۰/۰۵/۲۶	۴/۰۴	۲/۰۱	۲/۴۴	۱/۶۲	۰/۳۳	۰/۲۳	۳/۲۰	۴/۱۰	۱/۲۰	۶/۱۴	۵/۹۵	۴/۵۳
۹۰/۰۵/۲۷	۲/۹۶	۲/۰۹	۳/۱۴	۱/۳۹	۱/۳۱	۱/۲۹	۲/۷۹	۲/۲۱	۲/۶۴	۲/۹۹	۱/۴۴	۲/۳۷
۹۰/۰۵/۲۸	۱/۸۱	۱/۰۱	۰/۹۲	۲/۶۵	۰/۹۲	۰/۵۶	۱/۹۴	۱/۴۸	۰/۴۰	۰/۶۱	۴/۰۹	۲/۱۵
۹۰/۰۵/۲۹	۲/۰۷	۵/۷۷	۵/۲۳	۹/۰۲	۴/۴۴	۶/۰۰	۲/۹۰	۳/۸۸	۱/۶۹	۱/۷۰	۰/۹۶	۰/۱۵
۹۰/۰۵/۳۰	۱/۳۴	۲/۴۲	۱/۰۱	۸/۶۳	۵/۴۲	۶/۶۳	۵/۴۶	۴/۴۱	۶/۸۷	۱/۶۵	۳/۷۶	۱/۳۸
۹۰/۰۵/۳۱	۱/۰۰	۰/۸۶	۵/۲۱	۲/۱۴	۲/۰۲	۲/۰۳	۰/۶۸	۲/۸۷	۳/۴۷	۲/۸۶	۴/۶۹	۵/۱۸

ادامه جدول (۱-۴)

ساعت تاریخ	درصد خطای مطلق (APE)												MAPE
	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲	۲۳	۲۴	
۹۰/۰۵/۱	./۰۱	۱/۱۶	۴/۳۷	۱/۱۷	./۹۳	۱/۵۴	۲/۰۱	./۰۹	./۳۲	۴/۳۰	۱/۲۰	۲/۴۵	۲/۰۵
۹۰/۰۵/۲	./۰۴	۱/۲۱	۱/۵۹	./۹۹	۱/۲۹	۱/۴۷	۱/۵۲	۲/۱۶	۱/۴۹	۳/۶۴	۴/۴۶	۴/۹۷	۱/۸۴
۹۰/۰۵/۳	۲/۲۶	./۴۱	۱/۴۸	./۳۸	./۸۳	./۴۶	./۱۶	./۳۶	./۴۲	./۹۹	./۵۹	۱/۸۷	۱/۴۳
۹۰/۰۵/۴	./۰۲	./۸۴	./۴۲	۲/۵۹	۱/۰۸	۲/۴۲	./۶۱	./۸۴	./۴۲	./۳۵	./۴۵	./۸۰	۱/۲۲
۹۰/۰۵/۵	۱/۸۳	./۰۲	./۲۹	۳/۶۰	۲/۶۶	۲/۸۱	۱/۶۹	۳/۱۰	./۹۸	۱/۲۵	./۲۲	./۱۵	۱/۳۵
۹۰/۰۵/۶	۱/۲۶	۱/۱۰	۲/۰۳	۱/۸۷	۲/۶۲	۲/۸۱	۱/۷۵	./۳۸	./۱۹	۱/۳۹	۱/۵۲	۲/۱۵	۲/۱۱
۹۰/۰۵/۷	۱/۴۸	۲/۶۱	۳/۸۷	./۲۰	./۰۹	./۷۹	۲/۴۳	۱/۲۴	./۵۷	۱/۶۳	./۴۹	۱/۵۷	۱/۴۹
۹۰/۰۵/۸	۱/۰۵	۱/۱۸	۳/۲۴	۲/۲۴	۱/۴۱	۱/۶۱	۱/۹۸	./۵۷	./۷۲	۶/۷۱	۲/۸۵	۱/۰۹	۲/۳۳
۹۰/۰۵/۹	۱/۰۴	۱/۸۸	./۸۹	۱/۹۴	./۱۸	۲/۲۹	۲/۴۸	./۴۸	۳/۷۸	۱/۱۵	۱/۱۴	./۰۴	۲/۰۰
۹۰/۰۵/۱۰	۱/۰۸	./۴۹	۱/۰۷	./۸۰	۲/۹۲	۲/۶۳	۱/۴۸	۲/۱۸	۱/۸۳	۱/۳۴	۲/۱۱	۱/۹۳	۱/۹۲
۹۰/۰۵/۱۱	۱/۰۵	./۱۲	۱/۸۷	./۸۶	./۷۴	۱/۷۵	۳/۳۹	۱/۶۸	۱/۶۹	۱/۴۰	۲/۰۸	./۷۶	۲/۳۴
۹۰/۰۵/۱۲	./۱۶	۱/۵۴	۱/۲۴	۲/۲۰	./۲۹	./۴۰	./۰۰	./۷۲	./۹۶	./۹۱	./۹۳	۲/۲۹	۲/۲۴
۹۰/۰۵/۱۳	۳/۴۹	۱/۰۵	./۹۹	۱/۲۰	۳/۰۳	۱/۶۱	./۱۶	./۵۳	./۹۷	./۰۱	۲/۳۱	۱/۴۲	۲/۴۷
۹۰/۰۵/۱۴	۱/۱۷	./۸۸	۱/۴۶	./۲۳	۳/۲۱	۴/۵۸	./۰۹	۳/۲۶	۱/۶۲	۱/۶۸	۳/۵۱	./۹۳	۲/۸۸
۹۰/۰۵/۱۵	./۰ۮ	۱/۸۶	۳/۹۹	۳/۴۷	۶/۷۷	۵/۶۷	./۱۴	۱/۹۸	./۶۵	۹/۲۳	۴/۲۹	./۰۹	۲/۷۲
۹۰/۰۵/۱۶	./۷۶	./۰۳	۳/۳۴	۱/۵۴	۲/۱۴	۲/۵۳	۴/۰۶	./۴۰	./۸۶	۴/۰۳	./۰۵	۲/۳۸	۲/۷۲
۹۰/۰۵/۱۷	۳/۷۰	۱/۲۰	./۹۱	./۵۲	./۴۳	۱/۸۴	۴/۷۲	۱/۲۶	۲/۴۷	./۰۸	./۱۱	۲/۰۰	۲/۲۷
۹۰/۰۵/۱۸	۲/۸۹	۱/۷۴	۱/۰۴	./۹۲	۲/۷۳	۳/۵۳	۷/۰۵	۴/۲۲	۵/۸۸	۵/۹۴	۵/۳۱	۲/۵۷	۳/۲۷
۹۰/۰۵/۱۹	./۶۴	۳/۴۲	۱/۲۲	./۲۰	۱/۵۶	۲/۰۳	۴/۷۷	۴/۲۵	۳/۷۱	۲/۷۴	./۲۱	./۷۵	۱/۷۶
۹۰/۰۵/۲۰	./۱۹	./۷۷	۱/۱۵	۲/۳۲	./۷۶	۱/۸۷	./۱۷	۱/۹۵	۱/۳۹	۳/۲۴	۳/۳۶	۳/۲۴	۱/۳۳
۹۰/۰۵/۲۱	۳/۳۶	./۳۵	۱/۵۰	۴/۰۳	۲/۹۰	۳/۱۳	۱/۹۱	۷/۱۵	۴/۶۳	۱/۷۷	۱/۹۰	./۰۸	۲/۶۹
۹۰/۰۵/۲۲	۲/۲۷	۱/۹۹	./۰۵	./۷۲	۲/۶۸	./۴۴	۱/۳۱	۱/۸۸	۲/۶۷	۷/۷۱	۲/۸۲	۱/۲۳	۲/۱۳
۹۰/۰۵/۲۳	./۳۶	۱/۰۶	./۳۹	۱/۴۱	۱/۹۶	./۱۵	۱/۹۰	./۸۲	./۳۶	۲/۰۹	۱/۷۹	۲/۳۱	۱/۹۴
۹۰/۰۵/۲۴	۱/۰۳	./۴۹	۱/۵۸	۲/۳۹	./۹۶	۱/۸۹	۱/۸۳	./۱۱	./۳۹	./۰۵	./۲۶	./۰۸	۱/۴۰
۹۰/۰۵/۲۵	۳/۳۵	۱/۳۳	۳/۰۹	./۴۳	./۱۴	./۲۰	۱/۹۷	./۳۶	۱/۶۲	۱/۵۴	۲/۱۲	۳/۵۸	۲/۰۸
۹۰/۰۵/۲۶	۴/۴۶	۴/۹۸	۴/۹۴	۱/۱۵	./۵۴	۲/۸۰	۳/۴۱	۲/۷۶	۲/۴۵	۱/۹۸	./۴۵	۱/۰۱	۲/۷۸
۹۰/۰۵/۲۷	۳/۰۴	./۰۴	./۷۲	۱/۹۸	۲/۲۷	۳/۴۹	۲/۲۲	۱/۶۳	۱/۰۷	۱/۶۷	۱/۶۳	۱/۹۷	۲/۰۸
۹۰/۰۵/۲۸	./۰۹	۲/۳۸	۳/۴۸	۵/۷۰	۵/۷۰	۷/۷۸	۵/۱۵	۸/۵۸	۷/۰۵	۲/۷۷	۲/۱۵	۲/۳۱	۳/۰۳
۹۰/۰۵/۲۹	۹/۰۶	۱۱/۲۰	۲/۳۳	۱/۸۰	۶/۳۴	۳/۳۰	./۸۹	۱/۷۲	./۱۶	۴/۸۳	۲/۱۵	./۶۶	۲/۶۹
۹۰/۰۵/۳۰	۲/۸۸	۱/۰۷	۲/۶۳	۵/۰۵	۳/۰۰	۲/۰۰	۱/۲۴	./۲۰	۱/۹۱	۱/۶۷	./۴۰	۲/۲۴	۳/۰۵
۹۰/۰۵/۳۱	./۹۳	۳/۹۳	۱/۲۴	۳/۳۷	./۷۶	۳/۰۹	۲/۳۲	۲/۲۳	./۰۰	۱/۴۶	۱/۱۴	۱/۴۱	۲/۳۱

جدول ۴-۲- میزان درصد خطای مطلق و میانگین درصد خطای مطلق در بهمن ماه سال ۱۳۹۰

ساعت تاریخ	درصد خطای مطلق (APE)											
	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
۹۰/۱۱/۱	۲/۱۵	۴/۲۴	۳/۸۴	۲/۹۷	۱/۷۳	۰/۹۳	۴/۴۳	۵/۶۰	۵/۲۷	۰/۲۰	۴/۱۴	۸/۰۳
۹۰/۱۱/۲	۰/۷۷	۴/۲۲	۳/۳۷	۶/۵۴	۲/۵۳	۳/۰۳	۳/۹۹	۱۱/۴۰	۱۹/۹۸	۱۷/۴۳	۷/۳۵	۸/۷۰
۹۰/۱۱/۳	۰/۰۷	۲/۳۰	۳/۸۱	۷/۴۱	۳/۹۸	۱/۳۲	۱۰/۶۸	۱۲/۳۵	۱۱/۷۴	۱۹/۷۵	۱۰/۲۰	۱۰/۲۳
۹۰/۱۱/۴	۴/۸۱	۴/۰۶	۲/۸۶	۲/۷۹	۴/۴۴	۳/۰۴	۱/۶۹	۱/۵۷	۱۱/۱۹	۸/۰۵	۵/۳۳	۶/۳۷
۹۰/۱۱/۵	۶/۲۸	۶/۱۸	۶/۴۱	۸/۵۲	۸/۳۹	۵/۹۵	۷/۲۳	۲/۵۹	۴/۱۴	۱/۰۴	۲/۹۷	۱/۲۸
۹۰/۱۱/۶	۶/۴۹	۵/۶۳	۵/۰۳	۶/۱۱	۵/۸۶	۴/۴۱	۴/۳۴	۳/۹۷	۵/۱۱	۷/۱۲	۶/۸۳	۶/۵۱
۹۰/۱۱/۷	۰/۰۴	۰/۳۵	۰/۶۰	۰/۳۳	۰/۱۷	۰/۲۶	۰/۰۰	۲/۴۲	۰/۴۵	۲/۸۱	۲/۷۱	۰/۲۶
۹۰/۱۱/۸	۰/۷۷	۰/۴۷	۱/۷۲	۰/۷۱	۱/۴۱	۱/۰۷	۰/۹۱	۰/۶۸	۰/۸۸	۱/۳۲	۱/۵۹	۱/۸۹
۹۰/۱۱/۹	۰/۹۲	۱/۳۹	۲/۴۲	۱/۶۳	۱/۳۹	۲/۱۰	۰/۵۴	۱/۸۲	۱/۱۵	۴/۷۲	۱/۸۱	۲/۴۴
۹۰/۱۱/۱۰	۰/۸۴	۰/۱۷	۱/۰۱	۲/۱۶	۳/۲۸	۱/۷۸	۰/۱۲	۰/۰۳	۰/۴۳	۳/۲۰	۱/۲۰	۰/۴۸
۹۰/۱۱/۱۱	۲/۷۶	۳/۰۴	۱/۲۱	۲/۰۶	۰/۹۴	۰/۶۸	۱/۲۰	۱/۲۰	۲/۵۳	۱/۷۹	۳/۱۳	۰/۶۳
۹۰/۱۱/۱۲	۳/۴۴	۴/۸۷	۵/۷۱	۲/۸۹	۳/۴۲	۲/۹۸	۰/۷۸	۳/۲۲	۴/۴۸	۳/۶۸	۳/۲۷	۴/۷۴
۹۰/۱۱/۱۳	۱/۸۸	۱/۱۹	۱/۷۶	۰/۸۱	۲/۴۹	۰/۴۳	۰/۵۱	۲/۷۴	۰/۵۲	۳/۲۹	۵/۸۱	۶/۸۸
۹۰/۱۱/۱۴	۱/۹۰	۰/۷۵	۰/۶۲	۱/۵۵	۰/۹۳	۰/۳۷	۰/۱۲	۰/۴۱	۱/۴۸	۲/۷۵	۱۰/۱۵	۰/۳۵
۹۰/۱۱/۱۵	۰/۴۴	۰/۴۴	۱/۸۷	۰/۰۴	۱/۱۷	۰/۰۳	۰/۱۳	۰/۱۳	۳/۷۶	۱/۰۰	۳/۹۱	۳/۶۳
۹۰/۱۱/۱۶	۴/۰۴	۲/۱۹	۱/۰۴	۴/۲۵	۸/۹۱	۰/۲۴	۸/۳۶	۴/۱۱	۳/۴۸	۰/۵۷	۲/۶۰	۱/۶۰
۹۰/۱۱/۱۷	۱/۴۰	۰/۹۷	۳/۰۰	۲/۶۲	۳/۰۱	۰/۵۴	۴/۶۹	۲/۷۴	۳/۴۵	۰/۷۱	۰/۷۰	۰/۸۱
۹۰/۱۱/۱۸	۰/۸۱	۱/۱۸	۲/۲۵	۴/۰۳	۱/۶۱	۰/۶۸	۲/۰۲	۳/۵۳	۵/۴۶	۴/۱۰	۳/۳۹	۱/۹۸
۹۰/۱۱/۱۹	۰/۳۲	۳/۲۵	۳/۲۶	۲/۶۶	۴/۱۷	۲/۳۰	۰/۲۶	۰/۰۵	۳/۰۰	۲/۲۱	۱/۹۰	۰/۷۷
۹۰/۱۱/۲۰	۲/۱۳	۰/۰۴	۲/۳۸	۰/۲۳	۰/۲۰	۰/۲۳	۰/۰۹	۰/۴۸	۱/۱۸	۲/۰۸	۴/۸۸	۲/۱۲
۹۰/۱۱/۲۱	۱/۱۹	۸/۶۵	۶/۶۴	۲/۷۵	۵/۷۸	۰/۰۹	۷/۷۹	۲/۰۸	۲/۰۴	۳/۰۶	۱۲/۷۳	۲/۸۹
۹۰/۱۱/۲۲	۱/۱۶	۱/۳۲	۲/۰۸	۴/۳۸	۳/۹۹	۶/۷۸	۸/۲۲	۵/۹۸	۷/۹۷	۴/۴۰	۱/۲۶	۰/۰۹
۹۰/۱۱/۲۳	۷/۳۸	۰/۱۰	۴/۲۱	۴/۶۲	۲/۹۹	۲/۲۵	۰/۶۹	۲/۳۱	۰/۱۸	۶/۱۷	۰/۱۷	۲/۶۴
۹۰/۱۱/۲۴	۴/۸۴	۳/۸۹	۴/۶۲	۳/۲۶	۰/۵۶	۳/۰۲	۱/۳۹	۱/۱۹	۲/۳۳	۱/۷۴	۱/۳۸	۱/۳۱
۹۰/۱۱/۲۵	۱/۳۰	۰/۲۰	۰/۹۶	۳/۶۷	۱/۶۲	۰/۹۱	۲/۰۳	۳/۷۳	۰/۷۸	۲/۸۴	۳/۱۶	۱/۲۸
۹۰/۱۱/۲۶	۰/۷۲	۱/۶۶	۲/۶۶	۰/۱۸	۱/۲۷	۱/۳۶	۰/۰۶	۱/۱۲	۲/۵۱	۰/۲۲	۰/۵۶	۰/۵۵
۹۰/۱۱/۲۷	۱/۲۵	۰/۳۷	۰/۳۹	۰/۱۲	۰/۴۹	۰/۵۲	۱/۰۷	۰/۱۸	۲/۶۶	۳/۳۰	۵/۱۵	۰/۳۹
۹۰/۱۱/۲۸	۱/۳۲	۲/۲۸	۳/۳۳	۱/۴۴	۱/۲۵	۳/۳۴	۱/۷۴	۰/۷۲	۲/۱۵	۳/۶۳	۱/۱۹	۰/۴۸
۹۰/۱۱/۲۹	۰/۲۰	۲/۲۰	۵/۱۴	۱/۵۵	۴/۰۸	۱/۶۵	۰/۴۲	۰/۴۹	۰/۸۴	۱/۶۱	۱/۸۲	۱/۷۹
۹۰/۱۱/۳۰	۰/۶۱	۱/۸۴	۳/۳۸	۰/۷۳	۴/۱۳	۰/۹۵	۲/۲۳	۰/۲۰	۰/۹۳	۳/۷۲	۴/۲۵	۰/۱۵

ادامه جدول (۲-۴)

ساعت تاریخ	درصد خطای مطلق (APE)												MAPE
	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲	۲۳	۲۴	
۹۰/۱۱/۱	۳/۱۶	۷/۹۶	۲/۲۰	۳/۶۲	۸/۳۶	۳/۷۱	۱/۶۰	۳/۱۴	۵/۱۸	۱/۱۵	۳/۶۶	۲/۲۴	۳/۶۹
۹۰/۱۱/۲	۱۰/۷۷	۲/۰۹	۷/۰۶	۱/۵۷	۷/۸۷	۳/۷۰	۷/۰۹	۱۰/۹۱	۰/۵۷	۲/۰۳	۸/۳۴	۱/۴۴	۶/۳۶
۹۰/۱۱/۳	۱۴/۴۲	۱۸/۰۹	۲۳/۵۵	۹/۹۷	۱۰/۹۷	۳/۵۸	۷/۱۵	۸/۶۳	۱/۴۲	۴/۸۳	۲/۰۹	۴/۹۶	۸/۷۲
۹۰/۱۱/۴	۹/۳۲	۱/۶۱	۲/۴۴	۴/۲۵	۳/۳۲	۲/۰۲	۱/۹۴	۲/۷۰	۰/۲۸	۰/۸۴	۴/۹۹	۲/۹۴	۳/۸۹
۹۰/۱۱/۵	۴/۳۸	۵/۶۹	۶/۸۱	۶/۴۷	۰/۹۳	۲/۱۲	۰/۳۴	۲/۳۹	۱/۴۱	۱/۷۹	۱/۸۲	۰/۸۵	۴/۰۲
۹۰/۱۱/۶	۴/۹۱	۶/۱۹	۶/۷۲	۴/۸۶	۰/۷۶	۰/۹۲	۰/۳۵	۰/۳۱	۱/۸۱	۰/۵۱	۰/۶۳	۱/۷۷	۴/۰۷
۹۰/۱۱/۷	۰/۵۴	۲/۲۹	۱/۵۴	۳/۵۱	۰/۱۱	۱/۴۱	۰/۱۰	۱/۲۰	۱/۲۲	۱/۰۵	۱/۱۲	۰/۹۸	۱/۰۷
۹۰/۱۱/۸	۱/۰۴	۲/۶۳	۰/۸۵	۰/۴۴	۲/۱۱	۱/۲۱	۰/۱۴	۱/۳۲	۱/۵۰	۱/۲۴	۰/۴۲	۳/۰۴	۱/۲۴
۹۰/۱۱/۹	۵/۳۶	۲/۳۰	۱/۳۶	۳/۲۱	۴/۶۷	۲/۵۶	۰/۱۸	۰/۹۴	۱/۰۲	۰/۳۸	۰/۲۱	۱/۳۲	۱/۹۱
۹۰/۱۱/۱۰	۱/۸۰	۲/۰۱	۲/۴۹	۰/۶۱	۲/۹۷	۰/۳۹	۱/۸۱	۰/۲۴	۰/۳۴	۰/۳۴	۲/۸۴	۰/۱۷	۱/۲۸
۹۰/۱۱/۱۱	۰/۶۰	۰/۱۴	۴/۴۳	۲/۰۳	۳/۵۴	۲/۴۲	۲/۲۷	۰/۷۵	۱/۹۲	۱/۲۵	۴/۲۷	۱/۸۳	۱/۹۹
۹۰/۱۱/۱۲	۴/۴۱	۴/۳۵	۵/۳۵	۰/۷۲	۰/۶۴	۳/۲۶	۰/۹۲	۰/۱۸	۱/۰۶	۰/۵۸	۰/۷۸	۱/۸۰	۲/۸۱
۹۰/۱۱/۱۳	۲/۴۵	۴/۲۷	۳/۰۸	۴/۷۸	۴/۳۱	۴/۰۶	۱/۰۹	۱/۲۳	۱/۶۹	۰/۹۰	۰/۱۸	۰/۶۶	۲/۴۲
۹۰/۱۱/۱۴	۱/۷۸	۲/۳۱	۴/۶۵	۳/۹۶	۲/۵۴	۰/۲۲	۲/۴۱	۲/۰۳	۳/۹۰	۱/۶۹	۰/۰۲	۳/۲۸	۲/۰۹
۹۰/۱۱/۱۵	۸/۳۴	۷/۲۳	۰/۸۹	۳/۷۸	۰/۸۱	۱/۲۵	۲/۸۲	۴/۲۳	۳/۴۰	۱/۸۰	۶/۳۷	۲/۷۹	۲/۹۵
۹۰/۱۱/۱۶	۱/۲۲	۲/۳۴	۸/۲۹	۴/۱۰	۱/۷۲	۲/۰۴	۰/۳۶	۱/۳۱	۴/۹۳	۳/۵۶	۵/۳۷	۱/۸۹	۳/۵۶
۹۰/۱۱/۱۷	۲/۹۲	۴/۷۷	۷/۵۶	۳/۸۲	۱/۴۶	۲/۰۴	۱/۷۸	۰/۷۰	۰/۶۱	۱/۰۸	۳/۰۰	۰/۰۷	۲/۲۷
۹۰/۱۱/۱۸	۲/۶۴	۳/۸۶	۷/۳۰	۲/۹۱	۲/۳۶	۳/۶۰	۰/۹۰	۱/۸۲	۰/۶۲	۰/۶۵	۱/۴۴	۰/۹۵	۲/۵۴
۹۰/۱۱/۱۹	۰/۸۳	۱/۱۶	۱/۶۸	۰/۰۹	۲/۱۲	۱/۳۹	۴/۰۸	۱/۰۳	۰/۳۴	۲/۴۴	۲/۴۷	۰/۰۷	۱/۷۵
۹۰/۱۱/۲۰	۰/۴۹	۹/۴۹	۰/۶۲	۴/۶۴	۳/۷۴	۱/۸۱	۶/۷۹	۴/۵۲	۳/۵۴	۰/۱۰	۳/۲۶	۱/۴۳	۲/۸۰
۹۰/۱۱/۲۱	۸/۱۱	۵/۶۵	۲/۳۹	۱/۲۲	۴/۱۷	۱۵/۹۷	۱۱/۲۲	۰/۶۱	۰/۸۷	۵/۱۵	۱/۳۵	۰/۵۲	۴/۷۵
۹۰/۱۱/۲۲	۸/۱۷	۰/۴۰	۵/۸۶	۵/۱۸۹	۸/۸۹	۸/۰۱	۵/۷۵	۳/۹۸	۲/۲۷	۲/۸۷	۰/۰۴	۴/۲۲	۴/۴۴
۹۰/۱۱/۲۳	۴/۵۴	۹/۱۱	۳/۹۳	۰/۱۷	۳/۰۰	۷/۰۴	۳/۶۲	۶/۷۹	۷/۶۴	۵/۱۰	۲/۵۵	۳/۶۷	۳/۷۹
۹۰/۱۱/۲۴	۰/۹۱	۲/۷۷	۴/۷۶	۲/۱۵	۰/۲۳	۰/۰۲	۲/۰۹	۰/۴۹	۱/۷۳	۱/۷۴	۱/۱۷	۱/۹۹	۲/۰۷
۹۰/۱۱/۲۵	۲/۱۵	۲/۹۰	۶/۲۸	۳/۰۰	۳/۷۴	۴/۶۹	۰/۹۸	۱/۳۱	۰/۳۸	۱/۸۵	۰/۵۲	۰/۷۱	۲/۳۳
۹۰/۱۱/۲۶	۱/۳۹	۲/۲۲	۰/۱۴	۰/۹۲	۰/۷۰	۲/۷۴	۰/۷۹	۰/۴۰	۱/۱۴	۰/۱۱	۰/۸۵	۰/۵۵	۱/۰۳
۹۰/۱۱/۲۷	۰/۲۳	۰/۷۳	۰/۹۷	۰/۹۵	۰/۹۲	۲/۲۳	۰/۶۸	۰/۴۳	۰/۲۵	۲/۵۱	۲/۱۴	۰/۳۳	۱/۲۲
۹۰/۱۱/۲۸	۱/۵۰	۰/۸۴	۱/۰۵	۳/۲۱	۲/۱۴	۱/۸۷	۰/۲۸	۳/۱۶	۰/۱۷	۰/۲۸	۰/۹۶	۲/۲۷	۱/۷۳
۹۰/۱۱/۲۹	۰/۵۱	۱/۶۰	۱/۲۲	۰/۹۱	۰/۰۱	۲/۰۶	۰/۲۱	۱/۱۴	۰/۶۵	۱/۱۷	۰/۵۷	۲/۱۲	۱/۴۶
۹۰/۱۱/۳۰	۲/۳۵	۰/۹۱	۰/۴۳	۱/۴۴	۰/۵۴	۷/۰۵	۴/۳۷	۲/۷۶	۰/۵۹	۱/۲۱	۰/۷۸	۲/۲۷	۱/۹۹

همان‌طور که در جدول (۱-۴) مشاهده می‌شود، میانگین درصد خطای مطلق در روز یکشنبه ۳۰

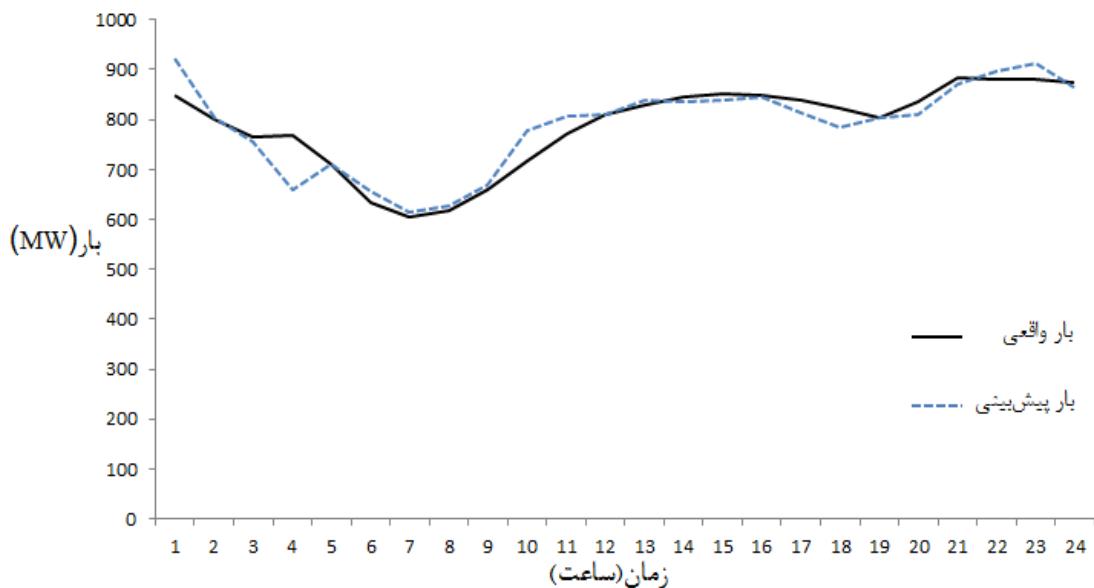
مرداد ماه که مصادف با شهادت حضرت علی (ع) است برابر ۳/۰۵٪ می‌باشد، که این مقدار درصد خطای

برای یک تعطیلی خاص مقدار بسیار مطلوبی است. در ادامه میزان درصد خطای مطلق تمام تعطیلات

قمری سال ۱۳۹۰ در جدول (۳-۴) آورده شده است.

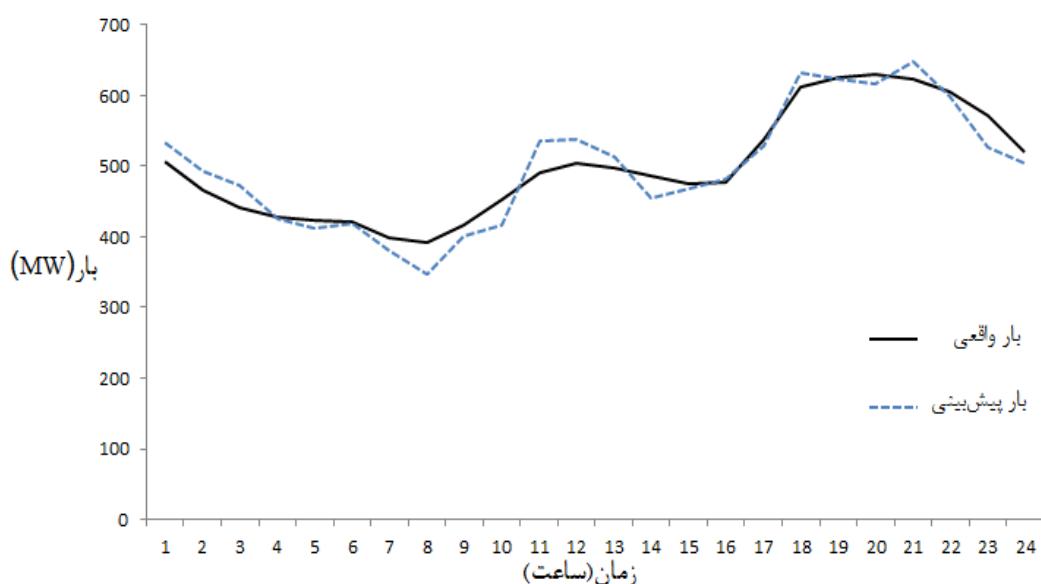
جدول ۴-۳- میانگین درصد خطای مطلق تعطیلات قمری سال ۱۳۹۰

مناسبت‌ها	میانگین درصد خطای مطلق (MAPE)
شهادت حضرت فاطمه	۵/۹۷
ولادت امام علی	۴/۵۳
بعث حضرت رسول اکرم	۵/۱۳
ولادت حضرت قائم	۴/۰۱
شهادت حضرت علی	۳/۰۵
عید سعید فطر	۵/۷۰
شهادت امام صادق	۵/۷۵
عید سعید قربان	۱/۵۶
عید سعید غدیر خم	۴/۸۳
تاسوعای حسینی	۶/۴۰
عاشورای حسینی	۵/۵۱
اربعین حسینی	۴/۷۹
رحلت حضرت رسول اکرم	۶/۳۶
شهادت حضرت امام رضا	۳/۸۹
میلاد حضرت رسول اکرم	۴/۷۵



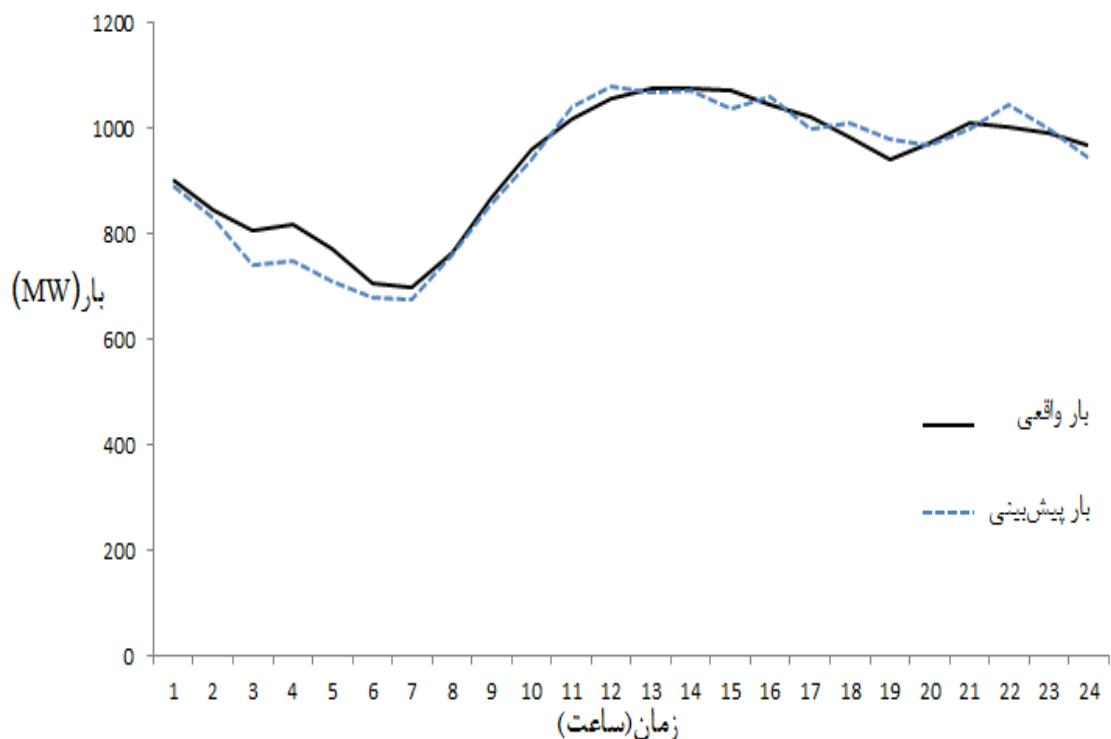
شکل ۴-۱۱- میزان بار واقعی و بار پیش‌بینی شده در ۱۴ مرداد سال ۱۳۹۰

همچنین پایین‌ترین دمای این سال با میانگین $8/325^{\circ}\text{C}$ - درجه سانتی‌گراد و مینیمم دمای $12/2^{\circ}\text{C}$ - درجه سانتی‌گراد در ساعت ۳ بامداد روز جمعه مورخ ۱۶ دی، روی می‌دهد. در این روز میانگین درصد خطای مطلق برای این مدل پیشنهادی برابر $4/22\%$ است. منحنی میزان بار واقعی و بار پیش‌بینی شده در این روز در شکل (۴-۱۳) نمایش داده شده است.



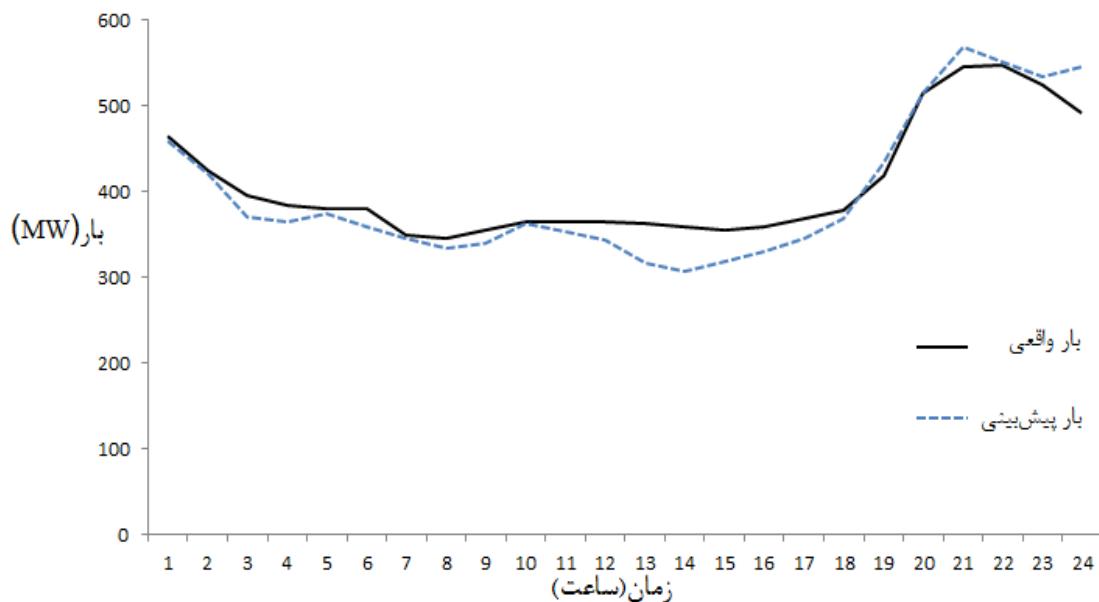
شکل ۴-۱۲- میزان بار واقعی و بار پیش‌بینی شده در ۱۶ دی سال ۱۳۹۰

حداکثر پیک سالیانه با میانگین بار $860/99$ مگاوات و ماکزیمم بار $1047/84$ مگاوات در ساعت ۱۴ روز یکشنبه مورخ ۱۶ مرداد روی می‌دهد. در این روز میانگین در صد خطای مطلق برای این مدل پیشنهادی برابر $2/72$ ٪ و در صد خطای مطلق برای ساعت پیک بار برابر $53/00$ ٪ است، که این توانایی مدل پیشنهادی در برابر تغییرات شدید بار را نشان می‌دهد. منحنی میزان بار واقعی و بار پیش‌بینی شده در این روز در شکل (۱۴-۴) نمایش داده شده است.



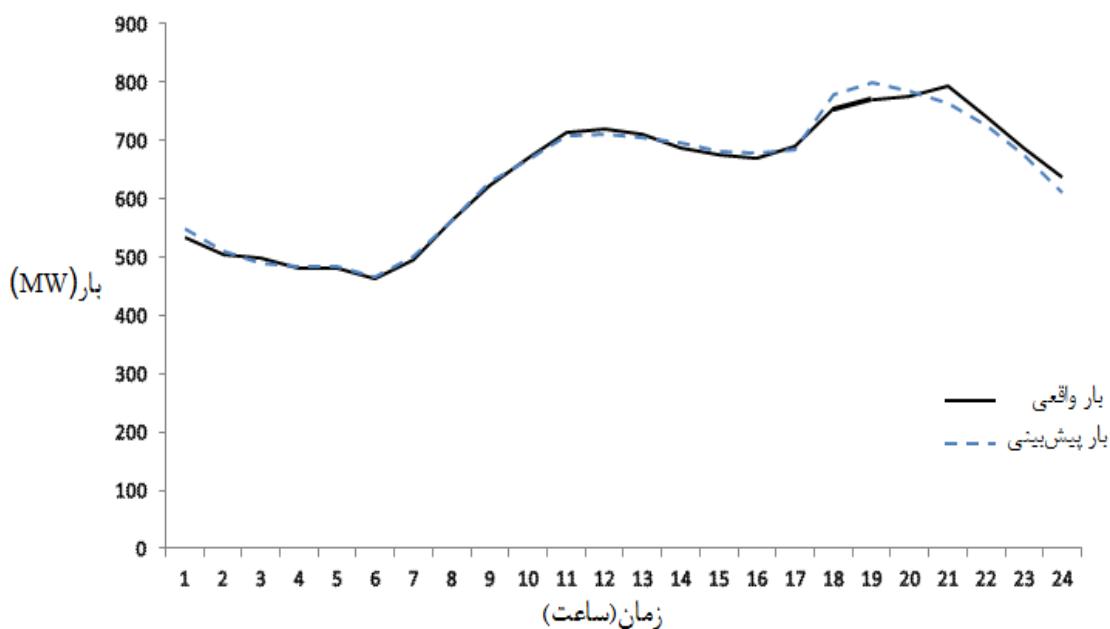
شکل ۱۴-۴- میزان بار واقعی و بار پیش‌بینی شده در ۱۶ مرداد سال ۱۳۹۰

حداقل بار سالیانه با میانگین بار $345/97$ مگاوات و مینیمم بار $375/35$ مگاوات در ساعت ۸ روز شنبه مورخ ۱۳ فروردین روی می‌دهد. در این روز میانگین در صد خطای مطلق برای این مدل پیشنهادی برابر $4/80$ ٪ و در صد خطای مطلق برای ساعت کمینه بار برابر $90/2$ ٪ است. منحنی میزان بار واقعی و بار پیش‌بینی شده در این روز در شکل (۱۵-۴) نمایش داده شده است.

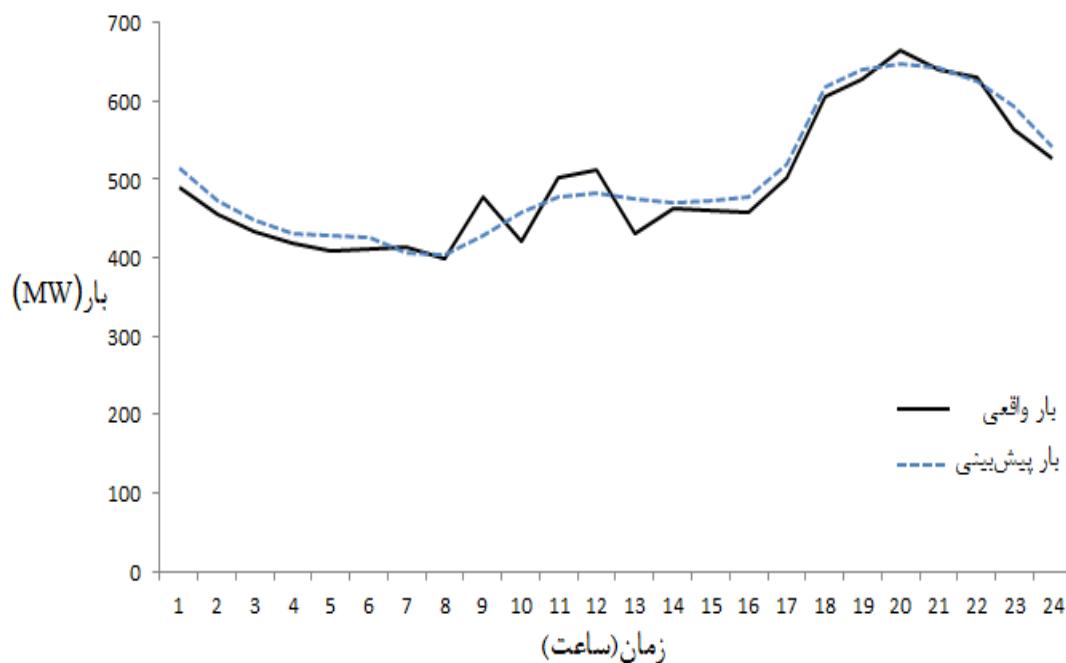


شکل ۴-۱۴- میزان بار واقعی و بار پیش‌بینی شده در ۱۳ فروردین سال ۱۳۹۰

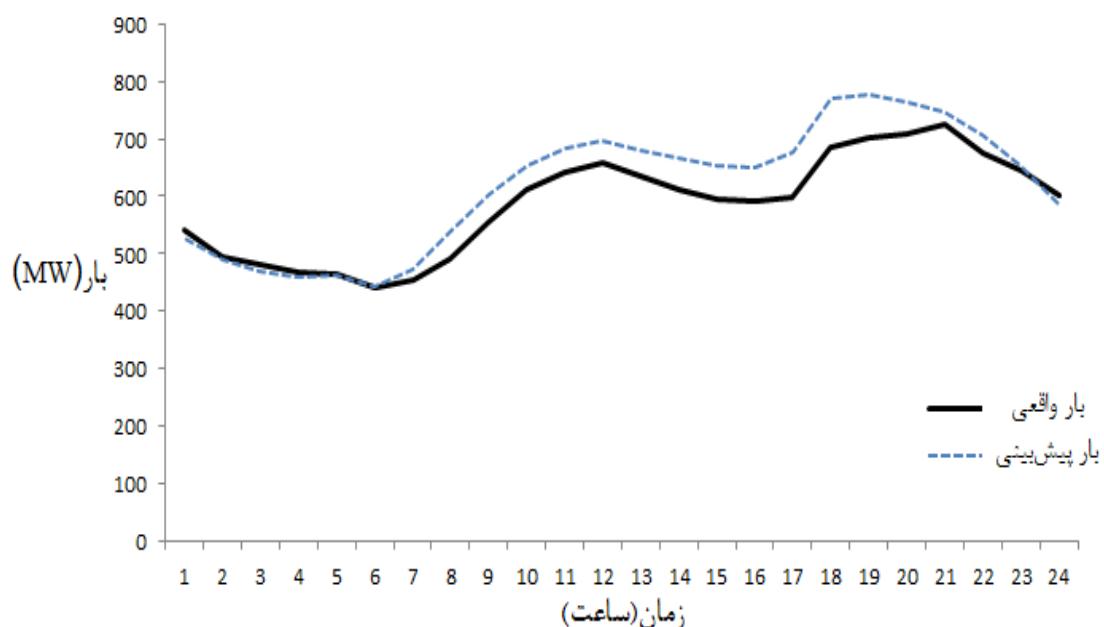
میزان بارهای واقعی و پیش‌بینی شده روزهای ۱۶ آبان (عید سعید قربان)، ۴ بهمن (شهادت امام رضا) و ۱۵ آذر (عاشرای حسینی) به عنوان نمونه‌ای از تعطیلات خاص به ترتیب در شکل‌های (۴-۱۶)، (۴-۱۷) و (۴-۱۸) آورده شده است.



شکل ۴-۱۵- میزان بار واقعی و بار پیش‌بینی شده در ۱۶ آبان سال ۱۳۹۰



شكل ۴-۱۶- میزان بار واقعی و بار پیش‌بینی شده در ۴ بهمن سال ۱۳۹۰



شكل ۴-۱۷- میزان بار واقعی و بار پیش‌بینی شده در ۱۵ آبان سال ۱۳۹۰

همان‌طور که مشاهده می‌شود، بارهای پیش‌بینی شده به خوبی بارهای واقعی را دنبال می‌کنند و این نشانه‌ای از عملکرد خوب شبکه می‌باشد.

فصل پنجم

نتیجه‌گیری و پیشنهادات

۱-۵- نتیجه گیری

پیش‌بینی بار کوتاه مدت از آنجا که براساس آن می‌توان زمان ورود و خروج نیروگاه‌های مختلف و همچنین میزان مشارکت آنها را در چرخه‌ی تولید تعیین نمود و از سوی دیگر اثرات عملکرد برنامه زمان‌بخشی را بر قابلیت اطمینان سیستم قدرت پیش‌بینی و برای افزایش آن چاره اندیشی نمود، بسیار مهم و مورد توجه می‌باشد. همان‌طور که گفته شد عوامل موثر بر مصرف بار دارای رابطه غیر خطی با بار می‌باشند. شبکه‌های عصبی مصنوعی دارای توانایی استخراج روابط غیرخطی دقیق را از میان متغیرهای ورودی، با استفاده از داده‌های آزمایشی می‌باشند. در این پایان‌نامه با استفاده از شبکه عصبی مصنوعی، پیش‌بینی بار کوتاه مدت برای ۲۴ ساعت آینده در شبکه برق شهرستان مشهد با هدف در نظر گرفتن تعطیلات شمسی و قمری انجام شد.

ابتدا داده‌های بدست آمده از شرکت توزیع برق شهرستان مشهد مورد تجزیه و تحلیل قرار گرفت. با بررسی منحنی بار مصرفی روزهای مختلف مشاهده شد که مصرف بار در ساعت‌های مختلف شبانه روز با یکدیگر تفاوت چشمگیری دارند. به همین دلیل در این پایان‌نامه با استفاده از روش تفکیک بین تک‌تک ساعت‌ها تفاوت قائل گردید. برای این منظور از ۲۴ شبکه عصبی مصنوعی که خروجی هر یک از آنها نشان دهنده پیش‌بینی بار ساعت مورد نظر است، استفاده گردید. استفاده از این روش باعث کاهش متغیرهای ورودی و سایز شبکه و به دنبال آن افزایش سرعت و ساده‌تر شدن آموزش شبکه عصبی و رسیدن به نتایج بهتر را به دنبال داشت. معماری هر ۲۴ شبکه یکسان و از نوع پیش- خور دو لایه بودند. همان‌طور که گفته شد این شبکه‌ها در مسائل تخمین توابع که پیش‌بینی بار کوتاه مدت نیز جزء همین مسائل می‌باشد، توانایی و دقت بالائی دارند. ساختار شبکه‌های عصبی شامل ۹ متغیر ورودی، ۱۰ نرون در لایه مخفی و ۱ نرون به عنوان مقدار بار پیش‌بینی شده به عنوان خروجی می‌باشد. تابع انتقال در لایه اول (لایه نهان) از نوع تانژانت سیگموید و تابع انتقال در لایه دوم (لایه خروجی) از نوع خطی انتخاب گردید. در این پایان‌نامه تعداد نرون‌های لایه نهان توسط روش صحیح و

خطا انتخاب شده است. آموزش این شبکه عصبی توسط الگوریتم لونبرگ-مارکوارت صورت گرفت. داده‌های استفاده شده برای آموزش شبکه عصبی شامل داده‌های سه سال شهرستان مشهد، از سال ۱۳۸۷-۸۹ بودند، که از ۸۰ درصد آنها به عنوان مجموعه آموزشی و از ۲۰ درصد آنها برای تست شبکه عصبی استفاده گردید. مدت زمان آموزش شبکه عصبی در این مدل به دلیل استفاده از روش تفکیک بسیار سریع و برابر ۷۳۰ ثانیه شد.

متغیرهای ورودی شبکه عصبی شامل ۹ ورودی از جمله: نوع روز ۱ (شنبه، یکشنبه، ...، جمعه)، نوع روز ۲ (روزهای عادی، روزهای قبل از تعطیل، روزهای بعد از تعطیل، روزهای مابین تعطیلات، تعطیلات نوروزی، تعطیلات شمسی، اعياد و ولادت های قمری، شهادت‌ها و مناسبتهای عزاداری قمری)، مصرف بار روز قبل از پیش‌بینی در همان ساعت، درجه حرارت روز قبل از پیش‌بینی در همان ساعت، پیش‌بینی درجه حرارت روز پیش‌بینی در همان ساعت، میزان رطوبت روز قبل از پیش‌بینی در همان ساعت، پیش‌بینی میزان رطوبت روز پیش‌بینی در همان ساعت، میزان سرعت باد روز قبل از پیش‌بینی در همان ساعت و پیش‌بینی میزان سرعت باد روز پیش‌بینی در همان ساعت می‌باشند.

برای ارزیابی دقت شبکه عصبی و تحلیل نتایج از داده‌های سال ۱۳۹۰ شهرستان مشهد استفاده کرده و از دو معیار درصد خطای مطلق برای تفکیک و بررسی خطاها استفاده شد. همان‌طور که مشاهده شد، میانگین درصد خطای مطلق سالیانه در این روش برابر $2/45$ درصد بود، همچنین میانگین درصد خطای مطلق برای تعطیلات خاص قمری برابر $4/81$ درصد، و درصد خطای مطلق برای این روزها مابین $1/59$ تا $6/40$ درصد بود، که این رقم قابل قبولی می‌باشد و نشان‌دهنده این است که بارهای پیش‌بینی شده به خوبی بارهای واقعی را تعقیب می‌کنند.

همچنین همان‌طور که در نتایج مشاهده شد، متغیرهای به کار برده شده در ورودی شبکه عصبی منجر به این شد که روش پیشنهادی در برابر تغییرات بار و آب و هوایی ناگهانی بسیار مطلوب عمل کند.

۲-۵- پیشنهادات

پیشنهادات زیر به منظور ادامه تحقیقات و بهبود نتایج پیش‌بینی بار کوتاه مدت ارائه می‌گردد:

- استفاده از الگوریتم‌های بهینه‌سازی جهت آموزش و انتخاب بهینه متغیرهای ورودی شبکه‌های عصبی.
- استفاده از روش‌های تفکیک دیگر به عنوان مثال استفاده از چهار شبکه عصبی که داده‌های هر فصل توسط یک شبکه عصبی به طور جداگانه آموزش بیینند.
- استفاده از چند نوع شبکه عصبی در کنار هم و میانگین‌گیری از آنها برای پیش‌بینی مطمئن تر بار کوتاه مدت.

مراجع

- [۱] M. O. Oliveira *et al*, “Climate change effect on very short-term electric load forecasting”, IEEE Trondheim PowerTech, pp. ۱-۷, ۲۰۱۱.
- [۲] B. Kermanshahi; R. Yokoyama; K. Takahashi, “Intelligent forecasting of distribution system loads”, in Proc. of Electrotechnical Conference MELECOM, vol. ۲, pp. ۷۸۴-۷۸۷, ۱۹۹۶.
- [۳] C. Guan et al, “Very short-term load forecasting: wavelet neural networks with data pre-filtering”, IEEE Transc. Power System, VOL. ۲۸, NO. ۱, pp. ۳۰-۴۱, Feb. ۲۰۱۳.
- [۴] J. W. Taylor, “An evaluation of methods for very short-term load forecasting using minute-by-minute British data”, International Journal of Forecasting ۲۴, pp. ۶۴۵-۶۵۸, ۲۰۰۸.
- [۵] Y. Wang, Q. Xia, C. Kang, “Secondary forecasting based on deviation analysis for short-term load forecasting”, IEEE Transc. Power System, VOL. ۲۶, NO. ۲, pp. ۵۰۰-۵۰۷, ۲۰۱۱.
- [۶] Y. Chen et al , “Short-Term Load Forecasting: Similar day-based wavelet neural networks”, IEEE Transc. Power System, VOL. ۲۵, NO. ۱, pp. ۳۲۲-۳۳۰, ۲۰۱۰.
- [۷] H. Mao et al, “Short-term and midterm load forecasting using a bilevel optimization model”, IEEE Trans. Power Del, Vol. ۲۴, No. ۲, pp. ۱۰۸۰-۱۰۸۹, ۲۰۰۹.
- [۸] N. Amjady, A. Daraeepour, “Midterm demand prediction of electrical power systems using a new hybrid forecast technique”, IEEE Transc. Power System, VOL. ۷, NO. ۲, pp. ۷۰۰-۷۱۰, ۲۰۱۱.
- [۹] Ü. B. Filik, Ö. N. Gerek, M. Kurban, “Neural and mathematical modeling approaches for hourly long term load forecasting”, ICIC Express Letters, VOL. ۳, NO. ۳, pp. ۱-۶, ۲۰۰۹.
- [۱۰] J. P. Rothe et al, “Hybrid and integrated approach to short term load forecasting”, International Journal of Engineering Science and Technology, Vol. ۲, No. ۱۲, pp. ۷۱۲۷-۷۱۳۲, ۲۰۰۹.
- [۱۱] M. Gui, T. Hang, “A Naïve multiple linear regression benchmark for short term load forecasting”, IEEE Power and Energy Society General Meeting, pp. ۱-۶, ۲۰۱۱.
- [۱۲] N. Amjady, “Short-term hourly load forecasting using time-series modeling with peak load estimation capability”, IEEE Trans. Power System, Vol. ۱۶, No. ۳, pp. ۴۹۸-۵۰۵, ۲۰۰۱.
- [۱۳] W. Christianse, “Short term load forecasting using general exponential smoothing”, IEEE Transactions on PAS, Vol. ۹۰, No. ۲, pp. ۹۰۰-۹۰۱, ۱۹۷۱.
- [۱۴] S .A. Villalba, C. A. Bel, “Hybrid demand model for load estimation and short-term load forecasting in distribution electrical systems”, IEEE Trans. Power Delivery, Vol. ۱۰, No. ۲, pp. ۷۶۴-۷۶۹, ۲۰۰۰.
- [۱۵] K. J. Hwan, G. W. Kim, “A short-term load forecasting expert system”, Proceedings of The Fifth Russian-Korean International Symposium on Science and Technology, Vol. ۱, pp. ۱۱۲-۱۱۶, ۲۰۰۱.

- [۱۶] A. A. Desouky, M. M. Elkateb, “Hybrid adaptive techniques for electric-load forecast using ANN and ARIMA”, IEE Proceedings of Generation, Transmission and Distribution, Vol. ۱۴۷, No. ۴, pp. ۲۱۳-۲۱۷, ۲۰۰۰.
- [۱۷] K. H. Kim, H. A. Youn, Y. C. Kang, “Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method”, IEEE Trans. Power System, Vol. ۱۵, No. ۲, pp. ۵۰۹-۵۱۵, ۲۰۰۰.
- [۱۸] O. Hyde, P. F. Hodnett, “An Adaptable automated procedure for short-term electricity load forecasting”, IEEE Trans. Power System, Vol. ۱۲, No. ۱, pp. ۸۴-۹۳, ۱۹۹۷.
- [۱۹] S. Ruzic, A. Vuckovic, N. Nikolic, “Weather sensitive method for short-term load forecasting in electric power utility of Serbia”, IEEE Trans. Power System, Vol. ۱۸, No. ۴, pp. ۱۰۸۱-۱۰۸۶, ۲۰۰۳.
- [۲۰] J. Y. Fan, J. D. McDonald, “A real-time implementation of short – term load forecasting for distribution power systems”, IEEE Trans. Power System, Vol. ۹, No. ۲, pp. ۹۸۸-۹۹۴, ۱۹۹۴.
- [۲۱] H. T. Yang, C. M. Huang, C. L. Huang, “Identification of ARMAX model for short-term load forecasting, An evolutionary programming approach”, IEEE Trans. Power System, Vol. ۱۱, No. ۱, pp. ۴۰۳-۴۰۸, ۱۹۹۶.
- [۲۲] H. T. Yang, C. M. Huang, C. L. Huang, “A new short-term load forecasting approach using self-organizing fuzzy ARMAX models”, IEEE Trans. Power System, Vol. ۱۳, No. ۱, pp. ۲۱۷-۲۲۰, ۱۹۹۸.
- [۲۳] M. Peng, N.F. Hubele, G.G. Karady, “Advancement in the application of neural networks for short-term load forecasting”, IEEE Trans. Power System, Vol. ۷, No. ۱, pp. ۲۰۰-۲۰۷, ۱۹۹۲.
- [۲۴] A .G .Bakirtzis, et al, “A neural network short-term load forecasting model for the Greek power system”, IEEE Trans. Power System, Vol. ۱۱, No. ۲, pp. ۸۰۸-۸۶۳, ۱۹۹۶.
- [۲۵] A. D. Papalexopoulos, S. Hao, T. M. Peng, “An implementation of a neural network based load forecasting model for the EMS”, IEEE Trans. Power System, Vol. ۹, No. ۴, pp. ۱۹۵۶-۱۹۶۲, ۱۹۹۴.
- [۲۶] A. Khotanzad, et al, “ANNSTLF - A neural-network-based electric load forecasting system”, IEEE Trans. Neural Networks, Vol. ۸, No. ۴, pp. ۸۳۰-۸۴۶, ۱۹۹۷.
- [۲۷] A. Khotanzad, R.A.Rohani, D. Maratukulam “ANNSTLF – Artificial neural network shortterm load forecaster - Generation three”, IEEE Trans. Neural Networks, Vol. ۱۳, No. ۴, pp. ۱۴۱۳-۱۴۴۲, ۱۹۹۸.
- [۲۸] B. J. Chen, M. W. Chang, C. J. Lin “Load forecasting using support vector machines: A study on EUNITE competition ۲۰۰۱”, IEEE Trans. Power System, Vol. ۱۹, No. ۴, pp. ۱۸۲۱-۱۸۳۰, ۲۰۰۴.
- [۲۹] T. W. S. Chow, C. T. Leung “Nonlinear autoregressive integrated neural network model for short-term load forecasting”, IEE Proceedings, Generation, Transmission and Distribution, Vol. ۱۴۳, No. ۵, pp. ۵۰۱-۵۰۷, ۱۹۹۷.

- [۳۰] J. P. Rothe, et al, “Hybrid and integrated approach to short term load forecasting”, International Journal of Engineering Science and Technology, Vol. ۲, No. ۱۲, pp. ۷۱۲۷-۷۱۳۲, ۲۰۱۰.
- [۳۱] Y. He, et al. “Short-term electrical load forecasting using a fuzzy ARTMAP neural network”, Machine Learning and Cybernetics Proceedings of ۲۰۰۹ International Conference, Vol. ۱۸, No. ۲۱, pp. ۴۷۶۰-۴۷۶۳, ۲۰۰۹.
- [۳۲] K.L. Ho et al, “Short-term load forecasting of Taiwan power system using a knowledge based expert system”, IEEE Trans. Neural Networks, Vol. ۵, pp. ۱۲۱۴-۱۲۲۱, ۱۹۹۰.
- [۳۳] S. Rahman, O. Hazim, “Load forecasting for multiple sites: development of an expert system-based technique”, Electric Power Systems Research, Vol. ۳۹, pp. ۱۶۱-۱۶۹, ۱۹۹۰.
- [۳۴] V. Miranda, C. Monteiro, “Fuzzy inference in spatial load forecasting”, Power Engineering Winter Meeting, IEEE, Vol. ۱, pp. ۱۰۶۳-۱۰۶۸, ۲۰۰۰.
- [۳۵] Y. Li, T. Fang, “Wavelet and support vector machines for short – term electrical load forecasting”, Proceedings of the International Conference on Wavelet Analysis and its Applications, Vol. ۱, pp. ۳۹۹-۴۰۴, ۲۰۰۳.
- [۳۶] X. Fan; Y. Xie; J. Yin, “Short-term load forecasting based on the method of genetic programming”, Mechatronics and Automation, ۲۰۰۷. ICMA, pp. ۸۳۹-۸۴۳, ۲۰۰۷.
- [۳۷] W. Sun, Y. Zou, “short term load forecasting based on BP neural network trained by PSO”, Machine Learning and Cybernetics, ۲۰۰۷ International Conference on, Vol. ۵ pp. ۱۹-۲۲, ۲۰۰۷.
- [۳۸] W. Sun'an, S. Wanxing “Short-term load forecasting using artificial immune network”, Power System Technology, ۲۰۰۲.
- [۳۹] Y. Chengqun, K. Lifeng, S. Wei “Hybrid neural network model for short term load forecasting”, Third International Conference on Natural Computation, ۲۰۰۷.
- [۴۰] M. Shahidehpour, H. Yamin, Z. Li, “Market operations in electric power systems: forecasting, scheduling, and risk managements”, Wiley-IEEE Press, ۲۰۰۲.
- [۴۱] L. Fausett, “Fundamentals of neural networks:archtectures, algorithms and applicatons”, Prentice Hall International, ۱۹۹۴.
- [۴۲] M. T. Hagan, H. B. Dcmuth, M. Beale, “Neural network design”, PWS Pub. Boston, ۱۹۹۶.
- [۴۳] D. Kriesel, “A brief introduction to neural networks”, http://www.dkriesel.com/en/science/neural_networks, ۲۰۰۷.
- [۴۴] S. Haykin, “Neural networks: A comprehensive foundation”, MacMillan Publishing Company, ۱۹۹۴.
- [۴۵] H. Demuth, “Neural network toolbox for use with MATLAB: User's guide”, MathWorks, Inc, ۲۰۰۰.

Abstract

Short time load forecasting has an important role in scheduling, utilizing and controlling of the power systems. accurate load forecasting results in practical decisions, such as maintenance, confident providence, unit commitment, economic dispatch and etc, to be improved. accurate short load forecasting according to the several effective load objects, such as weather conditions, daily, seasonal and temporary events with non linear load equations is a difficult job.

solving above problems, here, short load forecasting performed by using artificial neural networks. artificial neural networks are able to obtain accurate non linear equations from input variables by using experienced data. here the point is to decrease the error in short load forecasting problem with considering special days by using an appropriate artificial neural network and also choosing most effective load objects.

achieving this point feed forward artificial neural network with back propagation learning algorithm was studied and good results were obtained respectively. here to use neural network for the next ٢٤ hour load forecasting, real load and weather data were obtained from Mashhad electricity center and also Mashhad weather forecasting center.

Key words:

Short Term Load Forecasting, Artificial Neural Networks, Back Propagation Error



Shahrood University of Technology
Faculty of Electrical and Robotics Engineering

Short Term Load Forecasting Using Artificial Neural Networks

Mehdi Moazami Godarzi

Supervisor:
Dr. Mahdi Banejad

Advisor:
Dr. Mohsen Asili

September
۱۴۰۲