

# الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل ایران: کاربرد از الگوهای هوش مصنوعی

Hooseintahari@yahoo.com

محمدحسین طحاری مهرجردی

کارشناس ارشد مدیریت صنعتی، جهاد دانشگاهی  
یزد (نویسنده مسئول مکاتبات)

Babaeimaybodihamid@yahoo.com

حمید بابایی مبیدی

کارشناس ارشد مدیریت صنعتی، دانشگاه یزد

Rh.taghizadeh@yahoo.com

روح‌الله تقی‌زاده مهرجردی

استادیار و عضو هیئت علمی مجتمع آموزش  
عالی اردکان

پذیرش: ۱۳۹۱/۰۵/۳۱

دریافت: ۱۳۹۰/۰۴/۰۶

**چکیده:** وابستگی روزافزون زندگی بشر به انرژی موجب شده است تا این عامل به‌طور بالقوه و بالفعل در کارکرد بخش‌های مختلف اقتصادی کشورها نیز نقش بسیار مهمی ایفا کند. از این رو، مسئولان هر کشور باید تلاش کنند تا با پیش‌بینی هر چه دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به نحو مطلوب کنترل کنند. هدف پژوهش حاضر، الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل ایران با استفاده از الگوهای شبکه عصبی فازی، شبکه عصبی ژنتیک و شبکه عصبی است. از این رو، از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور به عنوان متغیر خروجی الگوهای پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو، به عنوان متغیرهای ورودی الگوهای پیش‌بینی استفاده شد. در پایان دقت نتایج پیش‌بینی الگوهای مختلف، با استفاده از شاخص‌های ارزیابی مقایسه گردید. نتایج ارزیابی نشان داد که الگوی شبکه عصبی فازی، نسبت به سایر الگوها از بیشترین دقت در پیش‌بینی مصرف انرژی در بخش حمل و نقل کشور برخوردار است. همچنین بر اساس نتایج تحلیل حساسیت ورودی‌ها به وسیله شبکه عصبی، ورودی جمعیت کشور به عنوان ورودی شناخته شد که بیشترین تأثیر را در مصرف انرژی دارد.

**کلیدواژه‌ها:** مصرف انرژی، رگرسیون چندمتغیره، شبکه عصبی، الگوریتم ژنتیک، شبکه عصبی فازی

در دهه‌های اخیر، از انرژی به عنوان یکی از عوامل مهم تولید یاد شده است، به طوری که در کنار سایر عوامل تولید، نقش تعیین‌کننده‌ای در حیات اقتصادی کشورها داشته و با توسعه و پیشرفت اقتصادی، اهمیت آن به طور فزاینده‌ای افزایش یافته است. وابستگی روزافزون زندگی بشر به انرژی موجب شده است تا این بخش به طور بالقوه و بالفعل، در کارکرد بخش‌های مختلف اقتصادی کشورها نیز نقش چشم‌گیری ایفا کند (بهبودی و همکاران، ۱۳۸۸). تأمین امنیت عرضه انرژی در دنیا، از مسائل راهبردی پیش روی همه دولت‌ها است. امروزه در ایران، تلاش‌ها در بخش مدیریت سمت عرضه انرژی متمرکز است و کمتر به مدیریت سمت تقاضای انرژی توجه می‌شود، در حالی که مدیریت تقاضای انرژی و تلاش برای استفاده بهینه از انرژی در همه کشورهای پیشرفته دنیا، از مهم‌ترین عوامل پیشرفت صنعتی پایدار بوده است (مبینی دهکردی و همکاران، ۱۳۸۸). ایران از منابع غنی و گسترده انرژی، مخازن بزرگ نفتی و گاز طبیعی، معادن عظیم زیرزمینی و پتانسیل بالقوه انرژی برخوردار است، پیش‌بینی مصرف انرژی می‌تواند در تبیین سیاست‌های بخش انرژی، کمک مؤثری کند. همچنین از آنجایی که مدتی است موضوع محدود کردن مصرف انرژی به ویژه فرآورده‌های نفتی مانند بنزین، در رأس سیاست‌های اقتصادی دولت قرار گرفته است و مشکلات ناشی از افت فشار گاز طبیعی، مانند قطع گاز در استان‌های مختلف یا کاهش تولید برق در کارخانجاتی که سوخت اصلی آنها، گاز طبیعی است، گاهی در کشور ایجاد می‌شود و کمبود منابع انرژی دیگر نیز گاهی برای بخش‌های مختلف اقتصاد، مشکل‌ساز می‌شود، پیش‌بینی و الگوسازی مصرف انرژی، می‌تواند رهنمود مناسبی برای سیاست‌گذاران بخش انرژی و اقتصاد کشور باشد (آماده و همکاران، ۱۳۸۸). روش‌های آماری و اقتصادسنجی، در مورد پیش‌بینی سری‌های زمانی عملکرد خوبی داشته است، اما محدودیت‌هایی نیز دارد، از جمله اینکه ممکن است در این گونه روش‌ها، فرم تبعی متغیرهای مستقل و وابسته در صورت عدم شناخت کافی به درستی تصریح نشود. علاوه بر این، داده‌های پرت ممکن است به تخمین اریب پارامترهای الگو بینجامد. در ضمن، بیشتر الگوهای سری زمانی، خطی است و بنابراین در تشریح رفتارهای غیرخطی ناتوان است (ابریشمی و همکاران، ۱۳۸۹). در پژوهش‌های اخیر، از الگوهای هوش مصنوعی به طور متداول به عنوان ابزار تقریبی غیرخطی استفاده شده است، به طوری که می‌توان با استفاده از آن بر مشکلات فوق فائق آمد (جوادی‌پور و کناب، ۲۰۰۳). هدف

پژوهش حاضر، کاربرد الگوهای هوش مصنوعی، یعنی الگوهای شبکه عصبی<sup>۱</sup>، الگوریتم ژنتیک<sup>۲</sup> و شبکه عصبی فازی<sup>۳</sup> در پیش‌بینی مصرف انرژی بخش حمل و نقل کشور است تا در پایان بتوان میزان کارایی این روش‌ها را در پیش‌بینی مصرف انرژی مقایسه کرد.

### پیشینه پژوهش

الگوسازی مصرف و تقاضای انرژی، مبتنی بر مصرف گذشته و رابطه این مصرف با متغیرهای دیگر نظیر متغیرهای اقتصادی، جمعیتی، آب و هوا و قیمت انرژی است که در ادامه خلاصه پژوهش‌هایی که درباره این موضوع انجام شده است، بیان می‌شود.

از جمله پژوهش‌های داخلی درباره کاربرد شبکه‌های عصبی در پیش‌بینی، می‌توان پژوهش‌های تغزبان و نصرآبادی (۱۳۸۵) به منظور پیش‌بینی مصرف فرآورده‌های نفتی، احمدی قراچه (۱۳۸۵) برای پیش‌بینی ماهیانه قیمت نفت خام، امین ناصری و کوچک‌زاده (۱۳۸۷) به منظور پیش‌بینی مصرف نفت گاز کل کشور، ابریشمی و همکاران (۱۳۸۷) برای پیش‌بینی قیمت گازوئیل، شکیبایی و همکاران (۱۳۸۷) برای پیش‌بینی تولید نفت خام در یازده کشور تولیدکننده، آذری و همکاران (۱۳۸۷) برای پیش‌بینی کوتاه‌مدت میزان مصرف گاز طبیعی شهر تهران، پورکازمی و اسدی (۱۳۸۸) برای پیش‌بینی پویای قیمت نفت خام، منهای و همکاران (۱۳۸۹) برای پیش‌بینی تقاضای انرژی بخش حمل و نقل کشور، صادقی و همکاران (۱۳۹۰) برای پیش‌بینی روزانه قیمت سبذ نفت خام، دشتی و همکاران (۱۳۹۰) برای پیش‌بینی قیمت نفت خام ایران و ابراهیمی (۱۳۹۱) برای پیش‌بینی میزان مصرف انرژی الکتریکی بخش کشاورزی را نام برد. از جمله پژوهش‌های خارجی درباره کاربرد شبکه‌های عصبی، می‌توان پژوهش‌های کالگیرو<sup>۴</sup> (۲۰۰۰) برای پیش‌بینی میزان انرژی گرمایی مصرفی در ساختمان‌ها و پیش‌بینی مصرف انرژی در یک ساختمان خورشیدی، نصر و همکاران (۲۰۰۲) برای پیش‌بینی مصرف بنزین در کشور لبنان، مورات و سیلان<sup>۵</sup> (۲۰۰۵) برای پیش‌بینی انرژی بخش حمل و نقل کشور ترکیه، پاو<sup>۶</sup> (۲۰۰۶) برای پیش‌بینی مصرف برق تایوان، سازن<sup>۷</sup> و همکاران (۲۰۰۷)، به

1. Neural Network
2. Genetic Algorithm
3. Fuzzy neural network
4. Kalogirou
5. Murat & Ceylan
6. Pao
7. Sozen

منظور پیش‌بینی مصرف فرآورده‌های نفتی در ترکیه، یو<sup>۱</sup> و همکاران (۲۰۰۸) برای پیش‌بینی قیمت حامل‌های انرژی، گیم و روپر<sup>۲</sup> (۲۰۰۹) برای پیش‌بینی تقاضای انرژی کره جنوبی، کولکارنی و حیدر<sup>۳</sup> (۲۰۰۹) برای پیش‌بینی قیمت نفت خام، اکونومو<sup>۴</sup> (۲۰۱۰) برای پیش‌بینی مصرف انرژی یونان و کانکال<sup>۵</sup> و همکاران (۲۰۱۱) برای پیش‌بینی مصرف انرژی ترکیه را نام برد.

همان‌طور که ملاحظه می‌شود، با توجه به اهمیت موضوع انرژی، پژوهش‌های متعددی درباره پیش‌بینی قیمت و مصرف انرژی انجام شده است که در هر کدام از آنها، بررسی و پیش‌بینی این موضوع‌ها با استفاده از روش خاصی انجام شده است. پژوهش‌های مذکور، به دو گروه تقسیم می‌شود: بررسی‌هایی که با روش اقتصادسنجی و پژوهش‌هایی که با روش هوش مصنوعی و شبکه‌های عصبی انجام شده است. در همه پژوهش‌های مذکور، کارایی و دقت بالاتر الگوهای شبکه عصبی تأیید گردید. در پژوهش حاضر نیز تلاش می‌شود تا با کاربرد سایر الگوهای هوش مصنوعی، یعنی الگوهای شبکه عصبی فازی و شبکه عصبی ژنتیک، مصرف انرژی بخش حمل و نقل ایران، پیش‌بینی و نتایج این الگوها با الگوهای سنتی مقایسه شود.

## مواد و روش‌ها

### شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی، توابعی جامع و انعطاف‌پذیر و ابزاری قدرتمند برای تجزیه و تحلیل داده‌ها و الگوسازی روابط غیرخطی، با درجه صحت بالا است. یکی از متداول‌ترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چندلایه<sup>۶</sup> است. پرسپترون چندلایه، یک ترکیب استاندارد از ورودی‌ها، واحدهای عصبی خطی و غیرخطی و خروجی‌ها است. خروجی همه واحدهای پردازش از هر لایه، به همه واحدهای پردازش لایه بعدی انتقال داده می‌شود. واحدهای پردازش لایه ورودی، همگی خطی است، ولی در لایه مخفی از نرون‌ها با تابع تانژانت سیگموئید<sup>۷</sup>، هایپربولیک<sup>۸</sup> یا هر تابع

1. Yu
2. Geem & Roper
3. Kulkarni & Haidar
4. Ekonomou
5. Kankal
6. Multi Layer Perceptron
7. Tangent Sigmoid
8. Hyperbolic

غیرخطی و پیوسته مشتق‌پذیر دیگری می‌توان استفاده کرد. برای افزایش سرعت آموزش، نرون‌های لایه خروجی خطی انتخاب می‌گردد. مسئله اصلی در این شبکه‌ها، تعیین تعداد لایه‌های پنهان و تعداد نرون‌های آنها است که نظرهای متفاوتی درباره آن وجود دارد. لایه پنهان از اهمیت بسیار بالایی در الگوهای شبکه‌های عصبی برخوردار است. در صورتی که تعداد کافی از این لایه‌ها و واحدها در یک الگوی شبکه‌های عصبی باشد، نقش مؤثری در فرایند یادگیری دارد. این لایه فقط یک نتیجه میانی در فرایند محاسبه ارزش خروجی است، از این رو، در اقتصادسنجی همتایی ندارد. دلیل اهمیت تعداد گره‌های مخفی این است که آنها نقش بسیار مهمی در خاصیت پیکره‌بندی غیرخطی شبکه‌های عصبی دارد (زانگ، ۲۰۰۳). لایه ورودی، دریافت‌کننده منابع خارج از سیستم است که این لایه در مورد مغز، به حواس پنجگانه تشبیه می‌شود. در تعیین تعداد گره‌های ورودی، استفاده از روش آزمون و خطا بیشترین کاربرد را دارد. اما به طور کلی، تعداد نرون‌های لایه ورودی، بیانگر تعداد متغیرهای ورودی است (مالیک و ناصر دین، ۲۰۰۶). نیلسون (۱۹۸۷) در این باره ثابت کرد که شبکه‌های عصبی با یک لایه مخفی با تابع سیگموئید  $f(x) = \frac{1}{1+e^x}$  در لایه میانی و تابع خطی در لایه خروجی، قادر به تقریب همه توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط به اینکه به اندازه کافی نرون در لایه مخفی وجود داشته باشد. این قضیه به تقریب‌ساز جهانی<sup>۱</sup> معروف است (منهاج، ۱۳۸۴).

### شبکه عصبی فازی (ANFIS)<sup>۲</sup>

شبکه‌های عصبی مصنوعی و سیستم‌های فازی با یکدیگر به لحاظ ساختاری متفاوت است، اما با توجه به ضعف‌ها و قوت‌های آنها، این دو سیستم، از ماهیت مکمل نسبت به یکدیگر برخوردار است. بنابراین، با ترکیب سیستم‌های فازی و شبکه‌های عصبی مصنوعی، قابلیت‌های یادگیری شبکه‌های عصبی، وارد سیستم‌های فازی خواهد شد. ژانگ اولین بار در سال ۱۹۹۳، الگو شبکه عصبی فازی را معرفی کرد. شبکه عصبی فازی از ویژگی‌هایی از جمله قدرت یادگیری، هزینه کردن، طبقه‌بندی، نوشتن و تدوین کردن برخوردار است. مزیت دیگر شبکه عصبی فازی این است که اجازه استخراج قوانین فازی را از داده‌های متعدد و تخصصی می‌دهد و به گونه‌ای متناسب، قوانین پایه و اساسی را می‌سازد. ساختار نرون فازی، همانند نرون فضای قطعی است، با این تفاوت که همه یا بعضی از اجزا و پارامترهای آن در قالب منطق فازی بیان می‌شود. برای تبدیل یک نرون معمولی به نرون فازی، راه‌های مختلفی وجود دارد که استفاده از هر کدام از آنها، ما را به انواع مختلفی از نرون‌های فازی

1. Universal Approximation
2. Adaptive-Network-based Fuzzy Inference Systems (ANFIS)

می‌رساند. پژوهش‌های اخیر، بیانگر قدرت و توانایی شبکه عصبی فازی در الگوسازی فرایندهای متعدد و مختلف است (زانگ، ۱۹۹۳؛ زانگ و همکاران، ۱۹۹۸).

### الگوریتم ژنتیک

نخستین بار هلند در سال ۱۹۷۵، الگوریتم ژنتیک را مطرح کرد و در سال‌های بعد، پژوهشگران دیگر آن را توسعه دادند. الگوریتم ژنتیک بخشی از نظریه محاسبه تکاملی است که در حال حاضر، به عنوان بخشی از هوش مصنوعی به سرعت در حال رشد است. ایده اصلی الگوریتم مذکور، در نظریه تکاملی داروین نهفته است. الگوریتم ژنتیک به لحاظ کاربردی، یکی از روش‌های بهینه‌سازی مسائل است که بنیان آن بر انتخاب طبیعی (عامل اصلی تکامل زیستی) و برخی از مفاهیم مهم از علم ژنتیک، استوار است. در این روش، برای بهینه‌سازی تابع هدف (تابع شایستگی) مسأله، از یک جمعیت اولیه کروموزوم‌ها (افراد) که در حقیقت پاسخ‌های اولیه مسأله هستند، به یک جمعیت جدید از کروموزوم‌ها یا یک نسل جدید که در حقیقت پاسخ‌های ثانویه مسأله مفروض است، می‌رسد. با تکرار این عملیات و تولید جمعیت جدید از جمعیت قبلی در هر مرحله و در نتیجه دستیابی به نسل‌های موفق، جمعیت به سمت یک پاسخ بهینه رشد خواهد کرد (قنبری و همکاران، ۱۳۸۷). بر اساس پژوهش‌های پیشین، الگوریتم‌های ژنتیک در بهبود عملکرد شبکه عصبی مصنوعی، سودمند خواهد بود. الگوریتم ژنتیک با کاهش تعداد تکرارها، موجب کاهش زمان یادگیری شبکه‌های عصبی می‌شود و می‌تواند در بهبود عملکرد پیش‌بینی نیز مؤثر باشد (منجمی و همکاران، ۱۳۸۸).

### شاخص‌های ارزیابی الگوها

نتیجه پیش‌بینی الگوها توسط شاخص‌های عملکرد مختلفی سنجیده می‌شود، زیرا هیچ اجماع کلی درباره بهترین معیار عملکرد، به منظور ارزیابی الگوی پیش‌بینی وجود ندارد (زانگ و هیو، ۱۹۹۸). در پژوهش حاضر، به منظور ارزیابی عملکرد الگوهای شبکه عصبی فازی، شبکه عصبی ژنتیک و شبکه عصبی مصنوعی، از پارامترهای خطای استاندارد نسبی (RSE) و میانگین خطا (ME)، مجذور میانگین مربعات خطا (RMSE) استفاده گردید که از روابط زیر قابل محاسبه است (سرمدیان و همکاران، ۱۳۸۹).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2} \quad (1)$$

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2}}{Z_{ave}} \quad (2)$$

$$ME = \frac{1}{n} \sum (Z_o - Z_p) \quad (3)$$

$$RI = \left( \frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (4)$$

که در آنها  $Z_0$  مقادیر پیش‌بینی شده،  $Z_p$  مقادیر مشاهداتی،  $Z_{ave}$  متوسط مقادیر مشاهداتی و  $n$  تعداد داده‌ها است.

#### مشخصات شاخص‌های ورودی و خروجی

از آنجایی که شبکه‌های عصبی مصنوعی، مبتنی بر داده است، آماده‌سازی داده‌ها، قدمی مهم و در واقع، کلید موفقیت در استفاده از شبکه عصبی است. هر چقدر تعداد داده‌ها بیشتر باشد، می‌توان درباره تقریب ساختار نهفته در الگو، اطمینان بیشتری حاصل کرد. در پژوهش حاضر، از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور (اعم از انرژی برق، گاز طبیعی و فرآورده‌های نفتی) به عنوان متغیر خروجی الگوهای پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو، به عنوان متغیرهای ورودی الگوهای پیش‌بینی استفاده شد که بازه زمانی این متغیرها، از سال ۱۳۴۷ تا سال ۱۳۸۵ است. شایان ذکر است که داده‌های سالانه این متغیرها، از منابع آماری وزارت نیرو و وزارت صنایع و معادن گردآوری شده (منهاج و همکاران، ۱۳۸۹) و تحلیل داده‌ها با استفاده از نرم افزارهای Minitab و Neuro solution انجام شده است. پژوهش حاضر، چندین مرحله دارد که در مرحله نخست، داده‌ها به دو دسته داده‌های تست و آموزش تقسیم شد. سپس از الگوریتم‌های شبکه عصبی، شبکه عصبی فازی و شبکه عصبی ژنتیک، برای پیش‌بینی مصرف انرژی استفاده گردید. در مرحله نهایی، با استفاده از شاخص‌های ارزیابی الگوها، نتایج الگوریتم‌های مختلف، ارزیابی و الگوی کارا و مناسبی برای پیش‌بینی مصرف انرژی بخش حمل و نقل کشور تعیین گردید.

نتایج

نتایج رگرسیون چندمتغیره خطی


در پژوهش حاضر، ابتدا، داده‌ها به دو دسته تقسیم گردید، به طوری که ۸۰٪ داده‌ها برای آموزش و بقیه داده‌ها یعنی ۲۰٪ برای اعتبارسنجی اختصاص داده شد. برای این منظور، دو دسته داده به‌طور تصادفی تعیین گردید. برای تعیین رگرسیون چندمتغیره پارامتر مورد بررسی، رابطه رگرسیونی مربوطه با استفاده از داده‌های آموزش تعیین گردید (معادله ۵). این رابطه سپس بر روی داده‌های آزمون اعمال گردید و نتایج ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا و ضریب تبیین به ترتیب ۶/۰۹، ۰/۰۵، ۵/۱۱ و ۰/۹۹۳ به دست آمد. مقادیر ضرایب رگرسیونی دارای عدد پی کوچک‌تر از ۰/۰۱ است، جدول تجزیه واریانس نیز برای رگرسیون محاسبه گردید که نتایج بیانگر معنی‌دار بودن معادله برازش داده شده است ( $p < 0.01$ ). در نهایت، پراکنش مقادیر خطا محاسبه شد که بیانگر صحت الگوی رگرسیونی و نبود همراستایی در بین پارامترهای ورودی است (جدول ۱). در نمودار (۱) دیاگرام پراکنش در داده‌های آزمون برای الگوی رگرسیون ارائه شده است.

$$y = -0.0826 + 0.290 X1 + 0.313 X2 + 0.483 X3 \quad (5)$$

که در معادله بالا  $X1$ : تعداد خودرو،  $X2$ : جمعیت،  $X3$ : تولید ناخالص داخلی و  $Y$ : مصرف نهایی انرژی بخش حمل و نقل کشور است.

جدول (۱): نتایج تجزیه واریانس برای رگرسیون

مقدار پی	اف فیشر	میانگین مربعات	مجموع مربعات	درجه آزادی	منابع
رگرسیون	۳	۱/۵۳۱	۰/۵۱۰	۵۳۶/۷۵	<۰/۰۱
باقیمانده خطا	۲۷	۰/۰۲۵	۰/۰۰۰۹۵		
کل	۳۰	۱/۵۵۷			



نمودار (۱): نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش رگرسیون



## نتایج شبکه عصبی


در طراحی الگوی شبکه عصبی، در واقع باید اندازه مجموعه یادگیری و آزمایشی، نرمال کردن داده‌ها، تعداد لایه‌های پنهان شبکه، تعداد نرون‌های هر لایه، الگوریتم‌های یادگیری، تابع تبدیل، تابع عملکرد، نرخ یادگیری و تعداد تکرارها مشخص گردد. در تعیین این موارد، روش‌های نظام‌مندی وجود ندارد، بنابراین، بهترین طراحی شبکه با استفاده از تجربه و آزمایش و خطا به دست می‌آید. در پژوهش حاضر، پس از تعیین مجموعه داده‌های آزمایش و آموزش داده‌های ورودی به شبکه با استفاده از رابطه (۶) استانداردسازی<sup>۱</sup> شد. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به دلیل تغییرات زیاد داده‌ها، تأثیر متفاوتی بر شبکه می‌گذارد، به طوری که برخی از نرون‌ها خیلی زود به حد آتش می‌رسد، در حالی که برخی دیگر از نرون‌ها حتی به آستانه فعالیت نیز نمی‌رسد و این باعث خواهد شد که توان پیش‌بینی الگو کم شود (منهاج، ۱۳۸۴). از این رو داده‌ها با استفاده از رابطه زیر استاندارد شود، یعنی بین یک دامنه عددی که معمولاً (۰/۱ و ۰/۹) است، قرار گیرد (سرمدیان و همکاران، ۱۳۸۹).

$$y = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (۶)$$

که در آن:  $X_{min}$  کوچکترین داده و  $X_{max}$  بزرگترین داده سری داده‌های ورودی است. با استفاده از این رابطه، داده‌های ورودی بین ۰/۱ و ۰/۹ قرار می‌گیرد.


در پژوهش حاضر، شبکه دارای تابع فعال‌سازی سیگموئید  $f(x) = \frac{1}{1+e^{-x}}$  در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی است و تعداد نرون‌های آن از یک تا ۱۰ نرون متغیر است و بهترین تعداد نرون به صورت سعی و خطا تعیین می‌شود. همچنین الگوریتم آموزشی لونیگ مارکوارت، به دلیل کارایی، سادگی و سرعت بالا مورد استفاده قرار گرفت. برای پیش‌بینی مصرف انرژی، ورودی‌های شبکه جمعیت، تعداد خودرو و تولید ناخالص داخلی بود. برای این ویژگی، مقادیر RMSE در شکل (۱) بیان شده است. با توجه به شکل (۱) ملاحظه می‌شود که حداقل مقدار RMSE مربوط به شبکه با نه نرون در لایه مخفی است. همان طور که در شکل دیده می‌شود، تغییرات RMSE روند مشخصی ندارد، از آنجایی که شبکه عصبی یک الگوی جعبه سیاه است و وزن‌ها به‌طور تصادفی انتخاب می‌شود، نمی‌توان روند موجود را به‌طور کامل توضیح داد. فقط باید با سعی و خطا، بهترین ساختار را به دست آورد. اما توجیهی که می‌توان بیان کرد، این است که با پیچیده‌تر شدن الگوی شبکه عصبی بیش از حد آموزش می‌بیند و قادر به برآزش مناسب بر روی داده‌های جدید نیست.

## 1. Normalization



شکل (۱): مقادیر RMSE برای تعداد نرون متفاوت


در نمودار (۲) پراکنش داده‌های آزمایش برای الگوی شبکه عصبی با ساختار ۱-۹-۳ که بهترین عملکرد را به خود اختصاص داده است، آورده شده است. با توجه به این شکل، ملاحظه می‌شود که بهترین خط برازش داده شده، زاویه‌ای نزدیک به ۴۵ درجه دارد که بیانگر دقت بالا است.



نمودار (۲): نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش شبکه عصبی

### نتایج شبکه عصبی فازی


در طراحی الگوی شبکه‌های عصبی فازی پژوهش حاضر، از شبکه عصبی چندلایه پیش‌خور، الگوریتم یادگیری پس انتشار خطا و نظام استنتاج فازی ساگنوا<sup>۱</sup> و تابع خروجی خطی و برای غیرفازی کردن، از تابع میانگین وزنی استفاده شد. برای طراحی نظام بهینه شبکه‌های عصبی فازی، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه پنهان، توپولوژی مناسب شبکه عصبی بررسی شد و با تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت، سیستم مناسب پایگاه استنتاج فازی طراحی شد. این شبکه ۲ تابع عضویت برای هر متغیر ورودی دارد (شکل ۲) و سایر پارامترهای آن، عبارت است از: تعداد مراحل آموزش = ۴۰، تولرانس خطا = ۰، نرخ‌های یادگیری برای لایه اول و دوم = ۰/۰۵. پارامترهای شبکه نیز با استفاده از سعی و خطا تعیین شد. در ضمن، ۸۰ درصد از داده‌ها به عنوان داده‌های آموزشی و ۲۰ درصد از داده‌ها به عنوان داده‌های آزمایشی و اعتبارسنجی انتخاب شده است. در نمودار (۳) دیاگرام پراکنش در داده‌های تست برای الگوی نروفازی که بهترین عملکرد را به خود اختصاص داده است، آورده شده است. با توجه به این شکل ملاحظه می‌شود که بهترین خط برازش داده شده، زاویه‌ای نزدیک به ۴۵ درجه دارد که بیانگر دقت بالای برآورد توسط الگوی شبکه عصبی فازی در تخمین پارامتر مورد بررسی است.



شکل (۲): ساختار ANFIS

جدول (۲): ویژگی‌های الگوی ANFIS انتخابی برای پیش‌بینی مصرف انرژی


تعداد توابع عضویت	تکرار	نوع تابع عضویت	روش یادگیری	روش دیفازی کردن	مصرف انرژی بخش حمل و نقل
۲	۴۰	مثلثی	هیبرید	میانگین وزنی	



نمودار (۳): نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش ANFIS

#### نتایج الگوی ترکیبی شبکه‌های عصبی و الگوریتم ژنتیک

در روش الگوریتم ژنتیک انتخاب جمعیت‌های اولیه تصادفی مختلف و تأثیرگذار در پدیده (که به عنوان داده‌های آموزشی از آنها یاد می‌شود) به منظور آموزش ماهیت‌ساز و کار حاکم بر پدیده، سبب پیچیدگی الگو و افزایش حافظه درگیر خواهد شد. در پژوهش حاضر، تعداد جمعیت اولیه ۵۰، حداکثر نسل ۱۰۰ و تعداد گردش برابر با ۱۰۰ دور در نظر گرفته شده است. در نمودار (۴) پراکنش در داده‌های آزمایش برای الگوی شبکه عصبی ژنتیک که عملکرد مناسبی را به خود اختصاص داده است، ارائه شده است. با توجه به نمودار مذکور ملاحظه می‌شود که بهترین خط برازش داده شده، زاویه‌ای نزدیک به ۴۵ درجه دارد که دقت بالای برآورد را توسط الگوی شبکه عصبی ژنتیک در تخمین پارامتر مورد بررسی نشان می‌دهد.



نمودار (۴): نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش شبکه عصبی ژنتیک

#### خلاصه نتایج و ارزیابی الگوهای پیش‌بینی


نتایج مربوط به الگوهای شبکه عصبی فازی، شبکه عصبی ژنتیک، شبکه عصبی و رگرسیون چندمتغیره مربوط به پارامتر مورد اندازه‌گیری، در جدول (۳) بیان شده است. با توجه به این جدول، ملاحظه می‌شود که در کل، بهترین عملکرد در پیش‌بینی ویژگی مورد بررسی، به الگوی شبکه عصبی فازی مربوط است و به لحاظ هر چهار معیار، بهتر از شبکه عصبی ژنتیک، شبکه عصبی و رگرسیون چندمتغیره است. بعد از الگوی ANFIS، الگوی شبکه عصبی ژنتیک و بعد از آن، به ترتیب الگوهای شبکه عصبی مصنوعی پس انتشار و رگرسیون چندمتغیره، بهترین عملکرد را به خود اختصاص داده است. همچنین یافته‌های پژوهش نشان داد که در سطح ۵٪، بین الگوهایی که مصرف انرژی را تخمین زده است، تفاوت معنی‌داری وجود ندارد. در چنین شرایطی، برای ارزیابی کارایی الگوها، می‌توان از شاخص RI استفاده کرد. این آماره بیانگر میزان کاهش خطا در الگوهای مختلف نسبت به روش رگرسیون است. همان‌طور که در جدول (۳) بیان شده است، الگوی نروفازی دقت پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای مصرف انرژی به میزان ۵/۷۷ درصد افزایش داده است.

جدول (۳): مقادیر واقعی و پیش‌بینی شده مصرف انرژی و عملکرد الگوهای مختلف

سال	مقادیر واقعی	رگرسیون	شبکه عصبی	شبکه عصبی ژنتیک	شبکه عصبی فازی
۱۳۵۰	۱۹/۶۸۵	۸/۶۱۳	۱۹/۸۴۷	۱۹/۵۰۹	۲۰/۱۶۲
۱۳۶۰	۵۳/۷۵۵	۵۷/۱۶۴	۵۷/۱۲۸	۵۴/۷۲۳	۵۵/۵۸۹
۱۳۶۵	۸۲/۷۹۴	۸۶/۴۶۲	۸۰/۷۱۶	۸۲/۵۴۲	۸۲/۳۴۶
۱۳۶۶	۸۶/۵۵۷	۸۸/۲۷۴	۸۲/۸۰۱	۸۵/۰۳۸	۸۴/۴۷۱
۱۳۷۴	۱۳۶/۹۷	۱۳۵/۹۵۵	۱۳۶/۰۹۹	۱۳۸/۲۰۱	۱۳۶/۰۸۳
۱۳۷۷	۱۶۱/۱۹۵	۱۵۷/۲۳۶	۱۶۳/۵۰۹	۱۶۶/۱۵۵	۱۶۲/۲۵۲
۱۳۷۸	۱۷۰/۱۹۶	۱۶۲/۶۲۹	۱۷۰/۲۹۵	۱۷۴/۵۹	۱۶۹/۴۴۲
۱۳۸۲	۲۲۰/۸۲۳	۲۱۲/۳۲۱	۲۲۶/۰۳۹	۲۲۲/۴۴۳	۲۲۵/۳۹۷
	RMSE	۶/۰۹	۲/۸۱	۲/۵۴	۱/۹۹
شاخص‌های	RSE	۰/۰۵	۰/۰۲۱	۰/۰۲	۰/۰۲
ارزیابی الگوها	ME	۵/۱۱	۲/۲۳	۱/۹	۱/۵۱
	RI	۰/۰۰	۵/۶۳	۵/۶۷	۵/۷۷

### تحلیل حساسیت شبکه‌های عصبی

تحلیل حساسیت در واقع روشی است که در آن با ایجاد تغییر در ورودی‌ها، میزان تغییر در خروجی مورد تحلیل قرار می‌گیرد. این موضوع، بیانگر آن است که کدام ورودی، بیشترین تأثیر را بر خروجی خواهد داشت (میرغفوری و همکاران، ۱۳۹۰). در پژوهش حاضر، برای پاسخ به این پرسش که کدام یک از متغیرهای ورودی (تعداد خودرو، جمعیت کشور و تولید ناخالص داخلی)، بیشترین تأثیر را بر خروجی‌ها (میزان مصرف انرژی) داشته، از تحلیل حساسیت در شبکه عصبی استفاده شده است. همان‌طور که در شکل (۳) مشاهده می‌شود، به ترتیب شاخص‌های جمعیت کشور ( $X_2$ )، تولید ناخالص داخلی ( $X_3$ ) و تعداد خودرو ( $X_1$ ) بیشترین تأثیر را بر خروجی یعنی میزان مصرف انرژی داشته است.



شکل (۳): تحلیل حساسیت شاخص‌های ورودی با استفاده از شبکه عصبی

### نتیجه‌گیری و پیشنهادها

انرژی عنصر اساسی تولید است که در اشکال مختلف از چوب و سوخت‌های فسیلی در پایین‌ترین سطح پالایش تا انرژی هسته‌ای در بالاترین سطح فرآوری در طبیعت وجود دارد. وابستگی روزافزون جوامع به انرژی، به دلیل جایگزینی نیروی ماشین به جای نیروی انسانی، سبب شده است که انرژی در کنار سایر عوامل تولید، عاملی مؤثر در رشد و توسعه اقتصادی تلقی شود و در عملکرد بخش‌های مختلف اقتصادی، نقش چشم‌گیری ایفا کند. از این رو، مسئولان جوامع مذکور سعی می‌کنند با پیش‌بینی هر چه دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به نحو مطلوب کنترل کنند. در پژوهش حاضر، با استفاده از الگوهای شبکه عصبی فازی، شبکه عصبی ژنتیک، شبکه عصبی و رگرسیون چندمتغیره، مقادیر انرژی مصرفی در بخش حمل و نقل ایران برآورد گردید. در پژوهشی مشابه که بدین منظور انجام شده، از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور به عنوان متغیر خروجی الگوهای پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو به عنوان متغیرهای ورودی الگوهای پیش‌بینی استفاده شده است (منهاج و همکاران، ۱۳۸۹). نتایج این بررسی نشان داد که در همه شاخص‌های ارزیابی، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی، کارایی بهتری داشته است، به طوری که نتایج پژوهش‌های پیشین در حوزه پیش‌بینی قیمت و مصرف حامل‌های انرژی،

مانند احمدی قراچه (۱۳۸۵)، امین ناصری و کوچک‌زاده (۱۳۸۷)، ابریشمی و همکاران (۱۳۸۷)، شکیبایی و همکاران (۱۳۸۷)، آذری و همکاران (۱۳۸۷)، منهاج و همکاران (۱۳۸۹)، صادقی و همکاران (۱۳۹۰)، دشتی رحمت آبادی و همکاران (۱۳۹۰) و پژوهش‌های یو و همکاران (۲۰۰۸) و غیره، دقت بیشتر الگوهای شبکه عصبی را نسبت به الگوهای رگرسیونی تأیید می‌کند. در پژوهش حاضر نیز تلاش شد تا با کاربرد شبکه‌های عصبی فازی و شبکه عصبی ژنتیک برای پیش‌بینی در حوزه انرژی، نتایج آن با الگوهای شبکه‌های عصبی و رگرسیون مقایسه شود تا کارایی این روش‌ها با سایر روش‌ها مقایسه شود. نتایج بررسی، بیانگر برتری الگوی شبکه عصبی ژنتیک بر شبکه عصبی و در نهایت، برتری الگوی شبکه عصبی فازی بر الگوی شبکه عصبی ژنتیک در پیش‌بینی مصرف انرژی است. همچنین نتایج تحلیل حساسیت شاخص‌های ورودی به وسیله شبکه عصبی، نشان داد که شاخص ورودی جمعیت کشور، بیشترین تأثیر را بر خروجی، یعنی مصرف انرژی دارد. شایان ذکر است که با توجه به ماهیت تقریبی بودن مقادیر و پارامترهای اندازه‌گیری شده، به نظر می‌رسد کارایی بیشتر الگوی مبتنی بر مجموعه‌های فازی در پیش‌بینی مصرف انرژی، به همین دلیل باشد. در پژوهش حاضر، کارایی الگوهای مذکور در پیش‌بینی مصرف انرژی در بخش حمل و نقل ایران بررسی شد. پیشنهاد می‌شود که در پژوهش‌های آتی، مصرف انرژی در سایر بخش‌های اقتصادی، پیش‌بینی و کارایی الگوهای مذکور سنجیده شود. علاوه بر این، با توجه به جستجوی تصادفی فضای جواب توسط الگوریتم ژنتیک و قابلیت شبکه عصبی برای درون‌یابی مسائل پیچیده، این الگوها با تعداد متغیرهای ورودی بیشتر، به نتایج بهتری منجر می‌شود که این موضوع، می‌تواند زمینه انجام پژوهش‌های آتی باشد.

منابع

#### الف) فارسی

ابراهیمی، مهرزاد (۱۳۹۱). استفاده از رهیافت‌های شبکه‌های عصبی مصنوعی و سری زمانی در پیش‌بینی میزان مصرف انرژی الکتریکی در بخش کشاورزی. *تحقیقات اقتصاد کشاورزی*، ۱، ۴۲-۲۷.



- ابریشمی، حمید؛ غنی‌امی فرد، حجت‌اله؛ احراری، مهدی و منیژه رضایی (۱۳۸۹). پیش‌بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی. *مطالعات اقتصاد انرژی*، ۲۴، ۱۹۲-۱۷۱.
- احمدی قراچه، احسان (۱۳۸۵). *ارائه یک مدل شبکه عصبی مناسب برای پیش‌بینی قیمت نفت با در نظر گرفتن شوک‌های نفتی* (پایان‌نامه کارشناسی ارشد). دانشگاه تربیت مدرس.
- آذری، احمد؛ شریعتی نیاسر، مجتبی؛ البرزی، محمود و افشین بختیاری (۱۳۸۷). *برآورد میزان بار گاز مصرفی شهر تهران با استفاده از فناوری شبکه‌های عصبی*. نشریه دانشکده فنی، ۴۲ (۸)، ۹۶۸-۹۶۱.
- آماده، حمید؛ قاضی، مرتضی و زهره عباسی‌فر (۱۳۸۸). بررسی رابطه مصرف انرژی و رشد اقتصادی و اشتغال در بخش‌های مختلف اقتصادی ایران. *تحقیقات اقتصادی*، ۶۶، ۳۸-۱.
- امین ناصری، محمدرضا و احمد کوچک‌زاده (۱۳۸۷). مدل طراحی بهینه معماری برای شبکه‌های عصبی مصنوعی و بکارگیری آن در پیش‌بینی مصرف ماهانه نفت گاز کل کشور. *مدرس علوم انسانی*، ۱۲ (۴)، ۶۹-۹۵.
- بهبودی، داوود؛ محمدزاده، پرویز و سودا جبرائیلی (۱۳۸۸). بررسی رابطه مصرف انرژی و تولید ناخالص داخلی در کشورهای در حال توسعه و توسعه یافته. *مطالعات اقتصاد انرژی*، ۶ (۲۳)، ۲۱-۱.
- تغزیان، آلبرت و نصرآبادی، ابراهیم (۱۳۸۵). پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصاد سنجی و شبکه‌های عصبی. *مطالعات اقتصاد انرژی*، ۳ (۱۰)، ۶۷-۴۷.
- دشتی رحمت‌آبادی؛ سیدابراهیم، محمدی و حمید و زکریا فرج‌زاده (۱۳۹۰). ارزیابی عملکرد الگوهای شبکه عصبی و خودرگرسیون میانگین متحرک در پیش‌بینی قیمت نفت خام ایران. *مطالعات اقتصاد انرژی*، ۸ (۲۸)، ۹۷-۱۱۸.
- سرمدیان، فریدون؛ تقی‌زاده مهرجودی، روح‌اله؛ محمد عسگری، حسین و اکبرزاده، علی (۱۳۸۹). مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره در پیش‌بینی برخی خصوصیات خاک (مطالعه موردی: استان گلستان). *تحقیقات آب و خاک ایران*، ۴۱ (۲)، ۲۲۰-۲۱۱.
- شکیبایی، علیرضا؛ نظام‌آبادی پور، حسین و سید جعفر حسینی (۱۳۸۸). پیش‌بینی عرضه نفت خام در یازده کشور تولیدکننده با استفاده از شبکه‌های عصبی و رگرسیون خطی. *دانش و توسعه*، ۱۶ (۲۷)، ۹۸-۱۱۹.
- صادقی، حسین؛ ذوالفقاری، مهدی و مجتبی الهامی‌نژاد (۱۳۹۰). مقایسه عملکرد شبکه‌های عصبی و مدل ARIMA در مدل‌سازی و پیش‌بینی کوتاه‌مدت قیمت سبده نفت خام اوپک (با تأکید بر انتظارات تطبیقی). *مطالعات اقتصاد انرژی*، ۸ (۲۸)، ۴۷-۲۵.
- قنبری، علی؛ خضری، محسن و آرش اعظمی (۱۳۸۷). شبیه‌سازی تابع تقاضای بنزین و نفت گاز در حمل و نقل زمینی ایران، با استفاده از روش الگوریتم ژنتیک. *اقتصاد مقداری* (بررسی‌های اقتصادی سابق)، ۴، ۱۷۷-۱۵۷.

مبینی دهکردی، علی؛ حوری جعفری، حامد و عطیه حمیدی‌نژاد (۱۳۸۸). بررسی وضعیت شاخص‌های مدیریت انرژی. راهبرد، ۱۱(۵۱)، ۲۹۱-۲۷۱.

منجمی، سید امیرحسین؛ ابزری، مهدی و رعیتی شوازی، علیرضا (۱۳۸۸). پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه آن با شبکه عصبی مصنوعی. *اقتصاد مقداری* (بررسی‌های اقتصادی سابق)، ۳، ۲۶-۱.

منهاج، محمدباقر (۱۳۸۴). *مبانی شبکه‌های عصبی*. تهران: دانشگاه صنعتی امیرکبیر.

منهاج، محمدباقر؛ کاظمی، عالیبه؛ شکوری گنجوی، حامد؛ مهرگان، محمدرضا و محمدرضا تقی‌زاده (۱۳۸۹). پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران. *مدرس علوم انسانی*. ۱۴(۲)، ۲۲۰-۲۰۴.

میرغفوری، سید حبیب‌اله؛ اسدیان اردکانی، فائزه و صادقی آرانی، زهرا (۱۳۹۰). طراحی مدلی برای ارزیابی و انتخاب پروژه‌های بهبود شش سیگما با استفاده از شبکه‌های عصبی مصنوعی. *مدیریت تولید و عملیات*، ۲(۲)، ۵۴-۳۷.

#### ب) انگلیسی

Ekonomou, L., (2010), Greek long-term energy consumption prediction using artificial neural network, *Energy*, 35: 512-517.

Geem, ZW., Roper, WE., (2009), Energy demand estimation of South Korea using artificial neural network, *Energy Policy*, 37: 4049-4054.

Jang, J. (1993), ANFIS: Adaptive-Neural-network-based Fuzzy Inference Systems. *IEEE Transactions on Systems, Man, and Cybernetics*. 23: 665-685.

Jang, J., Sun, C., & Mizutani, E. (1997), *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey, USA.

Javadpour, R & Knapp, GM. (2003), A fuzzy neural network approach to machine condition monitoring. *J Computers and industrial engineering*, 45, 323-330.

Kalogirou, S.A. (2000). Applications of artificial neural networks for energy systems, *Applied Energy*, 67, 17-35

Kankal, M., Akpınar, A., Komurcu, MI., Ozsahin, TS. (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88, 1927-1939.

Kulkarni, S. & Haidar, I. (2009). Forecasting Model for Crude Oil Price Using Artificial Neural Networks and Commodity Futures Prices. *International Journal of Computer Science and Information Security*, 2, 1-8.

Murat, Y & Ceylan, H. (2006). Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34, 3165-3172.

Nasr, G. E. Badr, E. A. & Joun, C. (2003). Backpropagation neural networks for

modeling gasoline consumption. *Energy Conversion and Management*, 44, 893-905.

Pao, H. T. (2006). Comparing linear and nonlinear forecasts for Taiwan's electricity consumption. *Energy*, 31, 2129-2141.

Sozen, A & Arcaklioglu, E. (2007), Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey, *Energy Policy*, 35, 4981-4992.

Yu, L., Wang, S. & Lai, K. K. (2008). Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm. *Energy Economics*, 30, 2623-2635.

Zhang, G., & Hu, M.Y. (1998). Neural Network Forecasting of The British Pound/ US Dollar Exchange Rate. *Omega, The International journal of management science*, 26, 495-506.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.