

ارزیابی عملکرد واحدهای تصمیم‌گیری با استفاده از مدل ترکیبی شبکه‌های عصبی پیش‌بینی‌کننده عملکرد و تحلیل پوششی داده‌ها (مورد مطالعه: شرکت ملی گاز ایران)

مهدی اجلی^{1*} و حسین صفری²

¹ عضو هیأت علمی مؤسسه آموزش عالی عبدالرحمن صوفی رازی - زنجان

² استادیار گروه مدیریت صنعتی - دانشکده مدیریت - دانشگاه تهران
(تاریخ دریافت 88/5/10، تاریخ دریافت روایت اصلاح شده 89/8/8، تاریخ تصویب 90/1/23)

چکیده

یکی از عمده‌ترین مشکلات استفاده از تحلیل پوششی داده‌ها، ضعف قدرت تفکیک‌پذیری برای واحدهای تصمیم‌گیرنده است. این مسئله اغلب به دلیل کم بودن تعداد واحدها در مقایسه با تعداد ورودی‌ها و خروجی‌های مدل است [1]. این مشکل در ارزیابی عملکرد 23 شرکت گاز استانی با توجه به تعداد زیاد ورودی‌ها و خروجی‌های هر شرکت گاز به خوبی خود را نمایان می‌کند. بر این اساس، در این پژوهش برای ارزیابی عملکرد و کارایی شرکت‌های گاز استانی، ابتدا رویکرد یا مدل مضربی CCR ورودی محور و روش اندرسون - پیترسون (AP) برای رتبه‌بندی واحدهای کارا در قالب مدل‌های تحلیل پوششی داده‌ها (DEA) مورد بررسی قرار گرفت و ضعف مدل‌ها از نظر محاسبه و تفکیک کارایی شرکت‌ها مشخص شد. در ادامه پژوهش، برای تحلیل و ارزیابی کارایی شرکت‌ها از رویکرد شبکه‌های عصبی پیش‌بینی‌کننده عملکرد در قالب مدل‌های ترکیبی تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی (Neuro/DEA) استفاده شد. نتایج تحلیلی کارایی محاسبه شده واحدها با استفاده از این مدل‌ها نشان از قدرت بالای شبکه در محاسبه و تفکیک‌پذیری شرکت‌ها از نظر کارایی بود.

واژه‌های کلیدی: تحلیل پوششی داده‌ها، شبکه‌های عصبی مصنوعی (ANNS)، Neuro-DEA، مدل CCR ورودی‌محور

مقدمه

به راهنمایی "کوپر" با عنوان "ارزیابی پیشرفت تحصیلی دانش آموزان مدارس ملی آمریکا" در سال 1976 در دانشگاه کارنگی مورد استفاده قرار گرفت و در سال 1978 در مقاله‌ای با عنوان "اندازه‌گیری کارایی واحدهای تصمیم‌گیرنده" ارائه شد، [2].

از آنجا که این مدل توسط چارنز، کوپر و رودز [Charnes et al, 1987] ارائه شد، به مدل CCR که از حروف اول نام این سه فرد تشکیل شده است معروف شد. در این مدل هدف اندازه‌گیری و مقایسه کارایی نسبی واحدهای سازمانی مانند مدارس، بیمارستان‌ها، شعب بانک، شهرداری‌ها و ... که چندین ورودی و خروجی شبیه به هم دارند است، [3].

بدیهی است که ایجاد یک نظام کارآ و استفاده بهینه از منابع، باعث جلوگیری از هدرز رفت مبالغ عظیمی از منابع مادی و معنوی می‌شود، به طوری که می‌تواند با درصد کمی افزایش در کارایی، صرفه‌جویی زیادی حاصل شود. بنابراین مطالعه سطح بهره‌وری در سطح شرکت‌های

اندازه‌گیری کارایی به دلیل اهمیت آن در ارزیابی عملکرد یک شرکت یا سازمان همواره مورد توجه محققان قرار داشته است. در سال 1957 فارل با استفاده از روشی مانند اندازه‌گیری کارایی در مباحث مهندسی اقدام به اندازه‌گیری کارایی برای یک واحد تولیدی کرد، موردی که فارل برای اندازه‌گیری کارایی مد نظر قرار داده بود، شامل یک ورودی و یک خروجی بود. مطالعه فارل شامل اندازه‌گیری کارایی‌های فنی، تخصصی و مشتق تابع تولید کارا بود. فارل مدل خود را برای تخمین کارایی بخش کشاورزی آمریکا نسبت به سایر کشورها مورد استفاده قرار داد. با این وجود، او در ارائه روشی که در برگیرنده ورودی‌ها و خروجی‌های متعدد باشد، موفق نبود، [2].

"چارنز (Charnes)"، "کوپر (Cooper)" و "رودز (Rohdes)" دیدگاه فارل را توسعه داده و مدلی را ارائه کردند که توانایی اندازه‌گیری کارایی با چندین ورودی و چندین خروجی را داشت. این مدل، تحلیل پوششی داده‌ها نام گرفت و ابتدا در رساله دکترای "ادوارد رودز" و

در سال 2007 سلیبی و بیرکتر مقاله‌ای با عنوان ترکیب تحلیل پوششی داده و شبه عصبی برای ارزیابی تأمین‌کنندگان تحت اطلاعات ناقص را مطرح کردند. انتخاب و ارزیابی تأمین‌کننده، فرآیندهای تصمیم‌گیری مهمی هستند که نیاز به ملاحظه نگرش‌های متنوعی دارند. مطالعات چندی برای انتخاب و ارزیابی مؤثر تأمین‌کنندگان با تکنیک‌های متعدد کاربردی نظیر روش‌های موزون خطی، مدل‌های برنامه‌ریزی ریاضی، روش‌های آماری و AI (هوش مصنوعی)¹ انجام گرفته است. یکی از روش‌های ارزیابی موفق پیشنهاد شده برای این هدف، تحلیل پوششی داده‌ها (DEA) است که تکنیک‌های برنامه‌ریزی ریاضی را برای ارزیابی عملکرد مجموعه‌ای از واحدهای تصمیم‌گیری مشابه (یکسان) با چندین ورودی و خروجی به کار می‌برد. هدف این مطالعه کشف یک ترکیب جدید از شبکه عصبی و تحلیل پوششی داده‌ها برای ارزیابی تأمین‌کنندگان تحت اطلاعات ناقص از معیارهای ارزیابی است، [10 و 11]

در این پژوهش سعی بر آن است که از شبکه‌های عصبی و DEA و تلفیق آن‌ها (Neuro-DEA) در اندازه‌گیری کارایی فنی شرکت‌های گاز استانی استفاده شود. پس از محاسبه کارایی، نتایج حاصله با DEA معمولی مقایسه می‌شود، زیرا با توجه به کم بودن تعداد شرکت‌ها، در مقایسه با تعداد ورودی‌ها و خروجی‌ها، مدل‌های پایه‌ای DEA قادر به رتبه‌بندی واحدها نیستند. ادامه مقاله به این ترتیب است که بخش دوم، نگاهی اجمالی بر مبانی DEA خواهد داشت و در بخش سوم شبکه‌های عصبی به طور خلاصه معرفی می‌شود، بخش چهارم به تشریح روش مورد استفاده و ساختار Neuro-DEA اختصاص یافته و در بخش پنجم، داده‌ها تحلیل می‌شود و بخش ششم به نتیجه‌گیری و پیشنهاد برای تحقیقات بعدی اختصاص یافته است.

تحلیل پوششی داده‌ها


DEA یک تکنیک ریاضی برای ارزیابی عملکرد واحدهای تصمیم‌گیرنده است. اولین بار چارلز، کوپر و رودز بحث DEA را مطرح کردند. به طور کلی مدل‌های تحلیل پوششی داده‌ها به دو گروه ورودی‌محور و خروجی‌محور تقسیم می‌شوند. مدل‌های ورودی‌محور، مدل‌هایی هستند که بدون تغییر در خروجی‌ها از ورودی‌های کمتری برای به دست آوردن همان مقدار

گاز استانی خیلی ضروری است. برای رسیدن به این هدف لازم است ابتدا عملکرد شرکت‌های گاز استانی مورد ارزیابی و تحلیل قرار گرفته و سپس استان‌هایی را که کارآ نیستند مشخص و علل نبود کارایی آن‌ها را تعیین و نسبت به رفع آن‌ها اقدام کرد.

روش‌های بسیاری برای اندازه‌گیری کارایی در تحقیقات مربوط مطرح شده است. اما در مقایسه بین همه مدل‌های ذکرشده، DEA روش بهتری برای سازماندهی و تحلیل داده‌ها است، زیرا اجازه می‌دهد که کارایی در طول زمان تغییر کند و به هیچ گونه پیش فرضی در مورد مرز کارایی نیاز ندارد. [4] بنابراین بیش از سایر دیدگاه‌ها در ارزیابی عملکرد مورد استفاده قرار گرفته است و تکنیک مناسبی برای مقایسه واحدها در سنجش کارایی به شمار می‌آید. با این وجود مرز کارایی که از DEA حاصل شده است نسبت به اغتشاش‌های آماری و داده‌های پرت که در اثر خطای اندازه‌گیری یا هر عامل خارجی دیگر ایجاد شود، حساس است و اگر در داده‌ها اغتشاش آماری یا داده‌ای پرت وجود داشته باشد، ممکن است سبب شود تا مرز کارایی به دست آمده جابه‌جا شود و مسیر تحلیل‌های DEA را منحرف کند؛ [4,5] به همین دلیل باید در استفاده از DEA برای ارزیابی عملکرد سایر واحدهای تصمیم‌گیرنده احتیاط کرد. این مسئله باعث شده است که به تازگی شبکه‌های عصبی مصنوعی به عنوان جایگزین خوبی برای برآورد مرزهای کارآ برای تصمیم‌گیری به کار گرفته شود. زیرا ماهیت عملکرد شبکه‌های عصبی به دلیل قدرت یادگیری و تعمیم‌پذیری به گونه‌ای است که در برابر داده‌های پرت و اغتشاش‌های حاصل از اندازه‌گیری غیردقیق داده‌ها مقاوم‌تر عمل می‌کنند. [6]


در سال 1997 کارای متروی لندن با داده‌های سری‌های زمانی تحلیل شد و این نتیجه به دست آمد که نتایج حاصل از ANNs با حداقل مربع‌های معمولی تصحیح شده و DEA بسیار به هم شبیه هستند. [7] در سال 2000 شبکه‌های عصبی برای تخمین توابع هزینه به کار گرفته شد [8] و در سال 2004 نیز سانتین از یک شبکه عصبی برای شبیه‌سازی تابع تولید غیرخطی استفاده کرد و نتایج آن را با روش‌های متداول تری مثل مرزهای تصادفی و DEA با مشاهدات مختلف و اغتشاش مقایسه کرد و نشان داد شبکه‌های عصبی در مقایسه با روش‌های ذکرشده ثبات بیشتری دارد. [9]

در شبکه‌های عصبی، نرون، کوچک‌ترین واحد پردازشگر اطلاعات است و اساس عملکرد شبکه عصبی را تشکیل می‌دهد. مدل یک شبکه عصبی تک نرون با یک ورودی و چند ورودی به شکل زیر است: (شکل‌های 2 و 3) در شکل (2) اسکالره‌ای p و a به ترتیب ورودی و خروجی هستند [14]



شکل 2: مدل نرون تک ورودی [14]

تابع محرک f می‌تواند خطی یا غیرخطی باشد. یک تابع محرک بر اساس نیاز خاص حل یک مسئله - مسئله‌ای که قرار است به وسیله شبکه عصبی حل شود - انتخاب می‌شود.



شکل 3: مدل یک نرون با m ورودی [15]

شکل (3) یک نرون با m ورودی را نشان می‌دهد که در آن X یک بردار ورودی با m عنصر $(x_1, x_2, \dots, x_m)$ است. وزن‌های سیناپسی هستند که میزان تأثیر X روی خروجی را نشان می‌دهد. b یک مقدار ثابت یا مقدار بایاس است و f تابع تبدیل است که ورودی خالص n را به خروجی تبدیل می‌کند. O نیز خروجی شبکه است. روابط بین متغیرهای ذکر شده به این ترتیب است [15]:

$$n = \sum_{i=1}^m x_i w_{1,i} + b = \vec{W} \cdot \vec{X} + b$$

$$\vec{X} = [x_1, x_2, \dots, x_m], \quad \vec{W} = [w_{1,1}, w_{1,2}, \dots, w_{1,m}] \quad (1)$$

$$O = f(WX + b)$$

شبکه‌های عصبی می‌توانند بیش از یک لایه داشته باشند. در شبکه‌های چند لایه هر لایه ماتریس وزن W و برای بایاس، $\vec{b}$ ، برای ورودی خالص، $\vec{n}$ و برای خروجی،

خروجی استفاده می‌کنند و مدل‌های خروجی محور آن‌هایی هستند که بدون تغییر در میزان ورودی، میزان خروجی‌های بیشتری را به دست می‌دهند. در یک تقسیم‌بندی دیگر، مدل‌های DEA به دو گروه مدل‌های مضربی و مدل‌های پوششی تقسیم بندی می‌شوند که مدل‌های پوششی ثانویه مدل‌های مضربی‌اند. در DEA برای اندازه‌گیری کارایی از نسبت مجموع موزون خروجی‌ها به مجموع موزون ورودی‌ها استفاده می‌شود. شکل (1) بیان‌کننده این وضعیت است:

$$\text{کارایی واحد } j \text{ ام} = \frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}}$$



شکل 1: یک واحد تصمیم‌گیرنده به همراه ورودی‌ها و خروجی‌ها

مدل مضربی CCR ورودی محور که بر اساس این مفهوم پی‌ریزی و به کار گرفته شده به این ترتیب است:

m : تعداد ورودی‌های هر DMU

s : تعداد خروجی هر DMU

n : تعداد DMU ها

y_{rj} : r امین خروجی DMU j ام

x_{ij} : i امین ورودی DMU j ام

u_r : وزن خروجی r ام

v_i : وزن ورودی i ام

مدل شماره 1- مضربی CCR ورودی محور

مرجع [12و13] فهرست کاملی از کتاب‌ها و مقالات در زمینه DEA را نشان می‌دهد.

شبکه‌های عصبی مصنوعی (ANNs)

معرفی اجمالی

شبکه‌های عصبی مصنوعی (ANNs) مدل‌های ریاضی‌ای هستند که نحوه عملکرد مغز انسان را تقلید می‌کنند و توانایی آنها در استخراج الگوها در داده‌های مشاهده شده بدون نیاز به داشتن مفروضاتی در مورد روابط بین متغیرها است.

آموزش شبکه‌های عصبی استفاده می‌شود. یکی از متداول‌ترین و پرکاربردترین شبکه‌های عصبی، شبکه‌های عصبی پرسپترون چند لایه با الگوریتم پس‌انتشار است. در الگوریتم پس‌انتشار⁷ خطا، داده‌های ورودی مکرر به شبکه داده می‌شود و خروجی با خروجی مطلوب مقایسه و خطا در هر تکرار محاسبه می‌شود. این خطا در طول شبکه منتشر و وزن‌های سیناپسی طوری تنظیم می‌شود که خطا در هر تکرار کاهش یابد [19]. در واقع پس‌انتشار یک روش واریانس کاهش یا افزایش است که تابع خطا (مجموع مربع‌های خطا) را با تعدیل وزن‌های سیناپسی (min) کمینه می‌کند.

متدولوژی و توپولوژی Neuro-DEA و الگوریتم‌های یادگیری شبکه

متدولوژی Neuro-DEA

در این پژوهش از یک شبکه پرسپترون چند لایه⁸ برای پیش‌بینی عملکرد واحدهای تصمیم‌گیرنده استفاده شده که به عنوان یک شبیه‌ساز می‌تواند عملکرد واحدها را در سال‌های بعدی شبیه‌سازی کند و با کمک آن به تحلیل حساسیت واحدها پرداخت. کارکرد شبکه مورد استفاده تخمین تابع اندازه‌گیری کارایی و تعمیم آن برای سال‌های بعدی است. این شبکه از داده‌های نرمال واحدها در سال 84 برای یادگیری استفاده کرده و الگوی کارایی را بر اساس توپولوژی شبکه و الگوریتم‌های یادگیری SCG و LM فرا می‌گیرد و با استفاده از الگوهای یاد گرفته شده، توان تعمیم آن برای داده‌های همان واحدها در سال‌های مختلف و از جمله سال 85 را دارد. خروجی شبکه، عددی است بین صفر تا یک که مقدار کارایی واحد را نشان می‌دهد. داده‌های ورودی شبکه نیز از ورودی‌ها و خروجی‌های هر واحد تصمیم‌گیرنده تشکیل شده است. این شبکه از یادگیری با ناظر استفاده می‌کند و بردار یادگیری آن کارایی‌ای است که قبلاً توسط DEA محاسبه شده است. در اینجا معیار خطایی تعریف می‌شود که با کمینه کردن آن، عوامل بهینه شبکه که همان وزن‌های سیناپسی هستند به دست می‌آید:

$$\text{Min } F = \sum_{i=1}^n (\underline{a}_i - \underline{t}_i)^2$$

$\underline{a}_i$: بردار خروجی شبکه به ازای i امین داده‌های ورودی

$\underline{t}_i$: بردار خروجی مطلوب به ازای i امین داده‌های ورودی

$\vec{0}$ مختص به خود را دارد. شبکه‌های عصبی را می‌توان به طور کلی به دو نوع شبکه‌های پیش‌خور² و شبکه‌های بازگشتی³ تقسیم‌بندی کرد. در شبکه‌های پیش‌خور هیچ بازخوردی از خروجی شبکه به ورودی شبکه داده نمی‌شود، ولی در شبکه‌های بازگشتی حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون‌های لایه و یا لایه‌های قبل وجود دارد. همچنین شبکه‌ها را می‌توان به شبکه‌های کاملاً متصل و شبکه‌های متصل جزئی دسته‌بندی کرد. در شبکه‌های متصل جزئی برخی از اتصالات سیناپسی حذف شده است [16].

در طراحی ساختار و معماری شبکه عصبی، تعداد عناصر بردار ورودی از صورت مسئله مورد بررسی مشخص شده و با انتخاب طراح نیست، ولی تعیین تعداد لایه‌ها، تعداد نرون‌های اولیه، نوع ارتباطات بین نرون‌ها، نوع تابع تبدیل و از این قبیل در انتخاب طراح است و بنابراین در شبکه‌های عصبی یک طراحی بهینه ضروری به نظر می‌رسد. [17]

یادگیری در شبکه‌های عصبی

به طور ساده یادگیری در شبکه‌های عصبی بدین معنی است که وزن‌های سیناپسی (W,b) طوری تغییر می‌کنند تا رابطه ورودی و خروجی نرون با هدف خاصی مطابقت کند. اغلب یادگیری در شبکه‌های عصبی به دو صورت انجام می‌گیرد. یادگیری بدون ناظر⁴ و یادگیری با ناظر⁵. در یادگیری با ناظر مجموعه‌ای از زوج‌های داده به نام داده‌های یادگیری اعمال می‌شود. مجموعه زوج یادگیری $\{(x_i, t_i), i=1,2,...,m\}$ که در آن x_i ورودی به شبکه و t_i خروجی مطلوب برای ورودی x_i است، پس از اعمال ورودی x_i به شبکه در خروجی شبکه O_i با t_i مقایسه شده و سپس خطای یادگیری محاسبه و از آن جهت تنظیم عوامل شبکه استفاده می‌شود در یادگیری بدون ناظر (یادگیری خودسازمانده)⁶ عوامل شبکه عصبی تنها توسط پاسخ سیستم اصلاح و تنظیم می‌شوند. به عبارتی فقط اطلاعات دریافتی از محیط به شبکه ورودی را تشکیل می‌دهد و بردار مطلوب به شبکه اعمال نمی‌شود [18]. روش‌های زیادی برای آموزش شبکه‌های عصبی ارائه شده است. روش گرادینان از متداول‌ترین آن‌ها است که البته برای شبکه‌های عصبی پیچیده خطای زیادی دارد. از الگوریتم‌های تکاملی مثل الگوریتم ژنتیک نیز برای

ANNs در ارزیابی عملکرد وجود دارد [20] که سه مورد زیر نمونه‌ای از این موارد است:

1- هیچ یک از مدل‌های DEA و ANNs هیچ پیش‌فرض اولیه‌ای در مورد نوع ارتباط بین ورودی‌ها و خروجی‌ها ندارند.

2- در DEA، به دنبال مجموعه‌ای از وزن‌ها هستیم، به طوری که کارایی فنی حداکثر شود. در حالی که ANNs به دنبال یافتن مجموعه‌ای از آن‌ها است، به طوری که اختلاف بین خروجی واقعی و خروجی مطلوب را به حداقل برساند و این کار را نیز با حداقل داده‌های یادگیری انجام می‌دهد.

3- هدف مدل Neuro-DEA، حداقل کردن ورودی‌ها نسبت به دستیابی به سطح خروجی مطلوب است. برای اندازه‌گیری کارایی شرکت‌ها با Neuro-DEA ابتدا یک مدل شبکه عصبی مناسب را شبیه‌سازی می‌کنیم، سپس با استفاده از داده‌هایی برای پردازش اولیه، داده‌های پیش‌پردازش، شبکه را با استفاده از خروجی مطلوب که با DEA محاسبه شده است، آموزش می‌دهیم تا جایی که شبکه بتواند الگوهای مرجع را یاد بگیرد و بر مبنای آن کارایی واحدها را محاسبه کند. سپس نتایج مشاهده شده با مدل DEA-CCR و Neuro-DEA را مورد بررسی قرار می‌دهیم.


توبولوژی Neuro-DEA

یکی از مباحث کلیدی در تقریب تابع، انتخاب معماری مناسب شبکه است. در موضوع تقریب ساز جهانی⁹ نشان داده شده است که شبکه‌های پیش‌خور با یک لایه مخفی با توابع تبدیل زیگموئیدی در لایه میانی و توابع تبدیل خطی در لایه خروجی قادرند توابع مختلف را با هر درجه تقریب، تقریب بزنند. لازم به ذکر است که تعداد نرون‌های لایه میانی باید به اندازه کافی باشد. این موضوع فقط کلیاتی را مطرح می‌کند که می‌توان به عنوان راهنما از آن استفاده کرد. در این تحقیق در تقریب تابع از این موضوع استفاده می‌کنیم، زیرا توابع پیوسته فرض شده است و همچنین X نیز بسته و کران‌دار است. بنابراین در ساختن شبکه از کلیاتی که این مسئله مطرح می‌کند بهره می‌گیریم تا بتوان به یک ساختار مناسب رسید.

برای تقریب توابع مطرح شده در فرآیند از یک شبکه دو لایه پیش‌خور که تابع تبدیل لایه پنهان تابع


پس از آنکه شبکه الگو را یاد گرفت، می‌توان از آن به صورت یک ابزار محاسباتی برای پیش‌بینی (شبیه‌سازی) کارایی در سال‌های دیگر نیز استفاده کرد.

در این مقاله همچنین برای نشان دادن نحوه محاسبه کارایی با ANNs از یک مطالعه موردی استفاده شده است، به طوری که برای ارزیابی عملکرد شرکت‌های گاز استانی (DMUs)، ورودی‌ها و خروجی‌هایی را مشخص کرده و کارایی را با استفاده از DEA (مدل CCR ورودی محور) اندازه‌گیری می‌گیریم. برای اندازه‌گیری کارایی از داده‌های مربوط به ورودی‌ها و خروجی‌های شرکت‌های گاز استانی در سال‌های 84-85 استفاده شده است. تعداد شرکت‌ها بیست و سه واحد و ورودی‌ها و خروجی‌ها به شکل زیر است: (شکل شماره 4)



شکل 4: ورودی‌ها و خروجی‌ها در هر شرکت

همان‌طور که در شکل (4) دیده می‌شود، در اندازه‌گیری کارایی فنی هر شرکت گاز استانی از چهار ورودی شامل هزینه‌های پرسنلی، غیر پرسنلی، عمرانی و محدوده شرکت و از سه خروجی شامل تأمین ایمنی، تأمین پایدار و برخورداری از گاز استفاده شده است. در عین حال متغیرهای متعددی هستند که در ارزیابی کارایی فنی هر شرکت گاز مورد ملاحظه قرار می‌گیرند و می‌توان اظهار داشت که کارایی هر شرکت گاز، تابعی از متغیرهای بالا است که تغییرات هر یک بر عملکرد شرکت تأثیر می‌گذارد. در این حالت می‌توان فرض خطی بودن رابطه بین متغیرها را نادیده گرفت و همچنین بر اساس قانون بازده نزولی و با در نظر گرفتن اثرات متقابل بین متغیرها، تابع کارایی واحد نام یعنی $f_i(X_1, X_2, X_3, X_4, Y_1, Y_2, Y_3)$ می‌تواند یک تابع غیرخطی باشد. با توجه به اینکه مدل DEA یک مدل خطی است و از طرفی شبکه‌های عصبی توانایی بالایی در تقریب توابع غیر خطی دارند، ANNs ابزار خوبی برای استفاده در چنین مسائلی است. بنابراین امکان به کارگیری ANNs در اندازه‌گیری کارایی شرکت‌ها مناسب است. همچنین مطالعات نشان می‌دهد که شباهت‌های زیادی بین DEA و



شکل 5: توپولوژی شبکه Neuro-DEA

الگوریتم یادگیری شبکه

پس از انتخاب ساختار شبکه، در مرحله بعد باید یک الگوریتم یادگیری مناسب انتخاب و بر اساس آن شبکه را آموزش داد. الگوریتم‌های متعددی برای آموزش شبکه وجود دارد. در اینجا از الگوریتم پس انتشار خطا (BP) استفاده می‌شود. الگوریتم BP استاندارد یک الگوریتم گرادیان کاهشی است. روش گرادیان کاهشی در بهینه‌سازی در برخورد با اولین بهینه محلی متوقف می‌شود. بنابراین روش‌هایی بر اساس همین الگوریتم توسعه یافتند که به روش‌های مبتنی بر جستجوی گرادیان مشهورند که در BP نیز مورد استفاده قرار گرفته‌اند. مشکل عمده این الگوریتم‌ها این است که در نقاط بهینه محلی گیر می‌افتند. به طور مختصر تعدادی از متداول‌ترین این الگوریتم‌ها مورد بررسی قرار می‌گیرد.

الگوریتم‌های پس انتشار خطا

در شکل (6) نوعی از شبکه، موسوم به MLP ترسیم شده است.

جایی که L تعداد لایه‌های شبکه را مشخص می‌کند و $\underline{P}$ بردار ورودی شبکه است، به عبارتی نرون‌های لایه اول، ورودی‌های خود را عناصر بردار $\underline{P}$ می‌سازند. خروجی لایه آخر، بردار خروجی کل شبکه را تشکیل می‌دهند، یعنی پاسخ واقعی شبکه، $\underline{a}$ ، برابر با $\underline{a}^L$ است. همان طور که بیان شد الگوریتم‌های متعدد پس انتشار وجود دارد که انتخاب آن به فرم مسئله نیز بستگی دارد. برخی از این الگوریتم‌ها سرعت بسیار کمی در همگرایی دارند و برخی دیگر سریع‌تر عمل می‌کنند. بنابراین الگوریتمی که بهترین عملکرد را در آموزش شبکه از خود نشان دهد، مورد استفاده قرار می‌گیرد. در این پژوهش از

زیگموئیدی و تابع تبدیل لایه خروجی خطی است، استفاده می‌شود. تعداد ورودی‌ها و خروجی‌های شبکه بر اساس تابعی که در مدل‌سازی فرآیند مطرح شد، مشخص است که تعیین‌کننده تعداد نرون‌های ورودی و خروجی است. در مورد تعیین تعداد نرون‌های لایه میانی نمی‌توان به طور قطع اظهار نظر کرد. اگر تعداد نرون‌ها کم باشد، شبکه در تعمیم دادن با مشکل مواجه خواهد شد. همچنین در صورتی که تعداد نرون‌ها زیاد باشد، علاوه بر آن پیچیدگی‌های محاسباتی نیز به همراه خواهد داشت. روش‌هایی ارائه شده است که می‌تواند تا حدی تعداد بهینه نرون‌های لایه پنهان را تعیین کند، اما در این تحقیق با آزمون و خطا تعداد نرون‌های لایه میانی را تعیین می‌کنیم؛ با این وجود تعیین دقیق تعداد نرون‌های لایه میانی کار آسانی نیست و به ماهیت مسئله بستگی دارد. در اینجا نیز برای تعیین نرون‌های لایه میانی از یک کران بالای تعداد نرون (30 نرون) استفاده شد و با دادن شرایط اولیه مختلف به مقدار وزن‌ها پس از یادگیری کامل از تعداد نرون کاسته و این فرآیند آن قدر تکرار شد تا تعداد نرون‌های مطلوب مشخص شد. در ابتدا با کاهش نرون، خطای شبکه نیز کاهش می‌یافت، تا اینکه از یک تعداد نرون ($n = n_1$) با کاهش نرون خطای شبکه افزایش یافت که در این هنگام n_1 را برابر n^* در نظر گرفتیم. در این توپولوژی همه توابع لایه میانی، تابع زیگموئیدی هستند. تابع خروجی نیز تابع خطی است. دلیل انتخاب تابع زیگموئیدی در لایه میانی قراردادن خروجی نرون‌های لایه میانی در مقیاس بین صفر تا یک است. خطی‌سازی لایه خروجی نیز در واقع ایجاد یک نگاشت یک به یک بین ورودی و خروجی نرون لایه آخر است که کارایی را نشان می‌دهد.

برای ساخت مدل Neuro-DEA از یک شبکه عصبی بیش‌خو¹⁰ بسیار معروف و متداول استفاده می‌کنیم. شبکه عصبی مدل Neuro-DEA یک پرسپترون چند لایه با الگوریتم پس انتشار خطا است که یک لایه خروجی و یک لایه پنهان دارد. تابع تبدیل لایه پنهان تابع تانژانت هیپربولیک¹¹ است و تابع تبدیل لایه خروجی یک تابع خطی است. در این شبکه، ورودی‌های شبکه شامل مجموع ورودی‌ها و خروجی‌های هر DMU است و خروجی مورد انتظار (O) شبکه کارایی هر DMU خواهد بود. شکل (5) شبکه عصبی مدل را نشان می‌دهد.

بر اساس رویه‌ای که در بالا بیان شد، انجام می‌شود. توابع دیگری مانند `traincg`، `traincgb` و `traincgp` وجود دارند که همگی آنها بر اساس گرادیان مزدوج عمل می‌کنند. لازم به ذکر است، نشان داده شده است که در بین الگوریتم‌های گرادیان مزدوج، الگوریتم گرادیان مزدوج مدرج سرعت همگرایی بالاتری دارد. بنابراین در این پژوهش از این الگوریتم که در نرم‌افزار MATLAB با `traincgp` نمایش داده می‌شود، برای آموزش شبکه استفاده شده است.

14 الگوریتم‌های شبه نیوتنی


در بهینه‌سازی غیر خطی، یکی از روش‌های متداول جستجوی گرادیان، استفاده از ماتریس هشین به عنوان ضریب گرادیان در مقدار تغییر وزن است. الگوریتم‌های مبتنی بر این روش به روش‌های نیوتنی و شبه نیوتنی معروف هستند که پایه همگی آنها یکی است. این الگوریتم‌ها نیز همانند الگوریتم‌های گرادیان مزدوج از سرعت همگرایی بالایی بهره‌مندند و حتی از آنها سریع‌تر همگرا می‌شوند.

نکته قابل تأمل درباره الگوریتم‌های نیوتنی، مشکلات محاسباتی است که برای محاسبه مشتق دوم (ماتریس هشین) وجود دارد. الگوریتم‌های شبه نیوتنی به طور مستقیم این ماتریس را محاسبه نمی‌کنند و در هر تکرار بر اساس تکرارهای قبلی ماتریس هشین به دست می‌آید. در نرم‌افزار MATLAB دو تابع `trainoss` و `trainbfg` از الگوریتم‌های شبه نیوتنی برای محاسبه وزن‌های بهینه استفاده می‌کنند.

15 الگوریتم لونیگ - مارکوارد

الگوریتم LM همانند الگوریتم‌های شبه نیوتنی از سرعت همگرایی بالایی بهره‌مند است، زیرا نیازی به محاسبه ماتریس هشین ندارد و به وسیله ماتریس جاکوبین آن را تقریب می‌زند [Hagan & Menhaj, 1994]. لازم به ذکر است هنگامی که ماتریس جاکوبین ابعاد بزرگی داشته باشد، مشکلاتی از نظر محاسباتی رخ می‌دهد، البته روش‌هایی وجود دارد که بر اساس آن نیازی به محاسبه همه عناصر ماتریس جاکوبین نیست. [20] در MATLAB تابع `trainlm` یکی از پرکاربردترین توابع یادگیری است که بر اساس یادگیری LM توسعه یافته است. در این

الگوریتم‌های گرادیان مزدوج و لونیگ مارکوارد برای یادگیری شبکه استفاده شده است. این الگوریتم‌های یادگیری در MATLAB7.1 وجود دارند.



شکل 6: شبکه پرسپترون چندلایه MLP [14]

معادلات زیر رفتار شبکه را بیان می‌کند:

$$\underline{a}^0 = \underline{p}$$

$$\underline{a}^{l+1} = \underline{f}^{l+1}(\underline{W}^{l+1} \underline{a}^l + \underline{b}^{l+1}) \quad ; \quad l = 0, 1, 2, \dots, L-1$$

12 الگوریتم‌های گرادیان مزدوج

همان‌گونه که بیان شد، الگوریتم پایه پس‌انتشار وزن‌ها را در جهت عکس گرادیان تغییر می‌دهد. ثابت می‌شود این جهت بیشتر میزان کاهش را به دنبال دارد، اما هیچ تضمینی برای سرعت همگرایی وجود ندارد. در الگوریتم‌های گرادیان مزدوج¹³، جستجو در جهت‌های مزدوج انجام می‌شود که سرعت همگرایی بیشتری دارد. الگوریتم‌های متعدد گرادیان مزدوج وجود دارد، یکی از الگوریتم‌های مزدوج که توسط فلچر و ریوز توسعه پیدا کرد به این شکل در یادگیری در شبکه عصبی مورد استفاده قرار می‌گیرد که ابتدا با عکس جهت گرادیان شروع می‌شود: [20] (رابطه 1)

$$P_0 = -\frac{\partial \hat{F}(\theta)}{\partial \mathbf{W}^T(\theta)} \quad (2)$$

به همین ترتیب وزن‌های جدید بر اساس رابطه‌های 2، 3 و 4 به دست می‌آید:

$$\mathbf{W}^l(k+1) = \mathbf{W}^l(k) + \alpha_k P_k \quad (3)$$

$$P_k = -\frac{\partial \hat{F}(k)}{\partial \mathbf{W}^T(k)} + \beta_k P_{k-1} \quad (4)$$

$$\beta_k = \frac{\left(\frac{\partial \hat{F}(k)}{\partial \mathbf{W}^T(k)} \right)^T \left(\frac{\partial \hat{F}(k)}{\partial \mathbf{W}^T(k)} \right)}{\left(\frac{\partial \hat{F}(k-1)}{\partial \mathbf{W}^T(k-1)} \right)^T \left(\frac{\partial \hat{F}(k-1)}{\partial \mathbf{W}^T(k-1)} \right)} \quad (5)$$

در نرم‌افزار MATLAB تابعی با عنوان `traincgf` تعریف شده است که با به کارگیری آن در شبکه عصبی، یادگیری

عنوان مقادیر حدی می‌شناسیم و باید آن‌ها را حذف کنیم، زیرا در تحلیل اریب ایجاد می‌کند، در اینجا نیز برای هر یک از ورودی‌ها و خروجی‌ها این فرآیند انجام گرفت که خوشبختانه هیچ یک از مقادیر ورودی و خروجی چنین شرایطی را نداشتند.

(ج) - رفع موارد کثیف

این بند مربوط به دقت جمع‌آوری کنندگان داده است که گاه در جمع‌آوری داده‌ها خطا وارد می‌شود. این داده‌ها باید شناسایی و حذف شوند، در اینجا با بررسی چند باره داده‌های جمع‌آوری شده و تطبیق آن با مستندات شرکت داده‌های کثیف به طور کامل اصلاح شد.

(د) - مدیریت مقادیر گم شده

در جمع‌آوری داده‌ها گاهی اوقات با مواردی رو به رو می‌شویم که داده وجود ندارد، به طور مثال یکی از داده‌های تأمین پایدار برای یک DMU وجود ندارد که باید مقدار مورد نظر با استفاده از روش‌های به کار گرفته شده در این بند جایگزین شوند، در اینجا همه داده‌ها موجود به جایگزینی داده جدید نبود.

نرمال‌سازی داده‌ها

پس از پیش‌پردازش داده‌ها، مسئله مهم دیگری که باید به آن توجه داشت، نرمال‌سازی یا هم‌مقیاس‌کردن داده‌ها است. مقیاس‌های متفاوت در متغیرهای مختلف نتایج نهایی را از جنبه‌های مختلف تحت تأثیر قرار خواهند داد. برای همین باید همه داده‌ها را هم‌مقیاس کرده و آن‌ها را تغییر شکل داد. بنابراین برای استانداردسازی میزان تأثیر هر متغیر بر نتیجه باید متغیرهای عددی را نرمال‌سازی کرد. روش‌های متعددی برای نرمال‌سازی داده‌ها وجود دارد، در این تحقیق از روشی که لاروس در کتاب مقدمه‌ای بر داده کاوی خود آورده است استفاده می‌کنیم. (Larose, 2005) با استفاده از این روش می‌توان داده‌ها را در هر فاصله دلخواه مانند $[L, H]$ مرتب کرد و به صورت زیر انجام داد:

$$X^* = mX + b \quad (6)$$

$$m = \frac{H - L}{\text{Max}(X) - \text{Min}(X)} \quad (7)$$

$$b = \frac{\text{Max}(X)L + \text{Min}(X)H}{\text{Max}(X) - \text{Min}(X)} \quad (8)$$

تحقیق از این الگوریتم نیز به سبب توان کارایی و یادگیری بالای آن استفاده شده است.

الگوریتم تحلیل کارایی

گام اول: جمع‌آوری اطلاعات مربوط به ورودی‌ها و

خروجی‌های DMU

در مطالعه سیستم‌های واقعی برای محاسبه کارایی، اولین گام تعیین ورودی‌ها و خروجی‌های هر DMU است، به طوری که منعکس‌کننده کارایی باشند. در تحلیل کارایی شرکت‌ها تعیین ورودی‌ها و خروجی‌ها اهمیت ویژه‌ای دارد، زیرا هر شرکت ورودی‌ها و خروجی‌های بسیار متعددی دارد که در نظر گرفتن تعداد زیادی از آن مشکلاتی را ایجاد می‌کند که در ادامه به آنها اشاره می‌شود. همچنین اگر تعدادی از این ورودی‌ها و خروجی‌ها نادیده گرفته شوند، مشکلاتی را در تحلیل کارایی ایجاد خواهد کرد. بعد از تعیین ورودی‌ها و خروجی‌های هر DMU برای مقایسه و اندازه‌گیری کارایی DMUها، اطلاعات مربوط به هر DMU را جمع‌آوری و آن را نرمالیزه می‌کنیم. روش نرمال‌سازی به کار گرفته شده در این پژوهش به این شرح است:

پیش‌پردازش داده‌ها

استفاده از شبکه‌های عصبی منوط به استفاده از داده‌های مناسب است. اکثر مدل‌های شبکه عصبی با داده‌ها سر و کار دارند، بنابراین لازم است قبل از استفاده از داده‌ها روی آن‌ها پیش‌پردازش انجام گیرد. در پیش‌پردازش داده‌ها گام‌های زیر به کار گرفته می‌شود:

(الف) - انتخاب متغیرهای مورد نیاز

متغیرهای مورد نیاز بر اساس مدل ارزیابی عملکرد تعیین می‌شود که شامل 4 ورودی (هزینه‌های پرسنلی، هزینه‌های غیرپرسنلی، هزینه‌های عمرانی، محدوده شرکت) و 3 خروجی (تأمین ایمنی، تأمین پایدار، برخورداری از گاز) است و همچنین کارایی به عنوان متغیر دیگر مورد نیاز است.

(ب) - حذف مقادیر دورافتاده

گاهی در جمع‌آوری داده‌ها با متغیرهایی رو به رو می‌شویم که بیش از حدود 3 انحراف معیار و 3- انحراف معیار از میانگین داده‌ها فاصله دارند. این متغیرها را به

گام چهارم: اگر با ارائه داده‌های آموزشی نتیجه و دقت مورد نظر حاصل شد (معیار خطا به میزان مورد نظر کاهش یافت) به گام بعد می‌رویم، در غیر این صورت به گام دوم برمی‌گردیم تا الگوی آموزش شبکه کامل شود. **گام پنجم:** محاسبه کارایی همه DMUها در سال 85 با استفاده از شبکه‌های عصبی پیش‌بینی کننده و آموزش یافته.

گام ششم: مقایسه بین نتایج حاصل از DEA و Neuro-DEA. در صورت لزوم می‌توان از تحلیل رگرسیونی و همبستگی بین نتایج دو روش استفاده کرد که در اینجا چون ممکن است DEA نتایج معتبری ندهد، از آن صرف نظر می‌شود. شکل 7 فلوچارت الگوریتم را نشان می‌دهد.

نتایج و یافته‌های تحقیق

همان‌طور که قبلاً بیان شد برای اندازه‌گیری کارایی و مقایسه واحدها از داده‌های سال‌های 84-85 شرکت‌ها استفاده شده است. پس از نرمالایزه کردن داده‌ها، کارایی هر یک از شرکت‌ها بر اساس ورودی‌ها و خروجی‌های آن‌ها محاسبه شد که با استفاده از DEA، مدل CCR ورودی‌محور، کارایی شرکت‌ها در سال‌های 84 و 85 به صورت جدول 5 است. البته لازم به ذکر است که اگر از مدل BCC در این حالت استفاده شود، نه تنها مشکل کمی تعداد DMUها را حل نمی‌کند، بلکه در واقع مدل BCC تعداد واحدهای کارایی بیشتری در مقایسه با مدل CCR معرفی می‌کند. بنابراین مشکل موجود شدیدتر نیز می‌شود.

در این رابطه X^* متغیر نرمال‌سازی شده و X_i متغیر اصلی است. برای نرمال‌سازی داده‌ها ترجیح داده شد که داده‌ها در بازه $[0,1]$ نرمال شوند. این کار به این دلیل است که بتوان اختلاف بین متغیرها را بهتر نشان داد. همچنین شبکه‌های عصبی با متغیرهای باینری و دو قطبی بهتر آموزش می‌بینند. همان‌طور که در مدل‌سازی مشخص شد، برخی از متغیرها، متغیر صفر یا یک یا به عبارت دیگر باینری بودند؛ با توجه به اینکه نرمال‌سازی در بازه $[0,1]$ انجام می‌گیرد.

اطلاعات مربوط به شاخص‌های ورودی و خروجی واحدها و همچنین مقادیر پارامترهای اشاره شده در فرمول‌های نرمال‌سازی داده‌ها در سال 84 در جداول (1) و (2) و در سال 85 در جداول (3) و (4) مشخص شده است.

گام دوم: بعد از جمع‌آوری داده با استفاده از مدل CCR کارایی همه DMUها محاسبه می‌شود. در این مرحله داده‌های لازم برای آموزش شبکه فراهم می‌شود. اگر تعداد DMUها زیاد باشد، می‌توان با استفاده از نمونه‌گیری، کارایی تعدادی از آن‌ها را محاسبه کرد. در این تحقیق از داده‌های مربوط به همه DMUها در سال 84 برای آموزش شبکه استفاده شده است. آماده‌سازی داده‌های یادگیری نیز مشکلاتی ایجاد می‌کند که در ادامه به آن اشاره می‌شود.

گام سوم: آموزش شبکه؛ در این مرحله شبکه عصبی با استفاده از داده‌های واحدهایی که در گام قبل انتخاب شدند، آموزش داده می‌شوند. وزن‌های شبکه طبق معادلات (2)، (3) و (4) تغییر می‌کنند.

جدول 1: مقادیر عوامل اشاره شده در فرمول‌های نرمال‌سازی داده‌ها در سال 84

	هزینه پرسنلی	هزینه غیر پرسنلی	هزینه‌های عمرانی	محدوده شرکت	تأمین ایمنی	تأمین پایدار	برخورداوری	کارایی
MAX	191472	264448	949788	3079523	76/90238	109/8504	2584555	100
MIN	5605	16913	0	34315	20/342	0	27027	71/24478
m	5/07416E-06	3/55E-06	1/05E-06	3/21E-07	0/010283	0/009103	3.83E-07	0/00584
b	0/02844066	0/060111	0	0/01102	0/209184	0	0/010349	0/416041

جدول 2: داده‌های نرمال شده واحدها به همراه کارایی محاسبه شده با مدل DEA در سال 84

واحد	هزینه پرسنلی	هزینه غیر پرسنلی	هزینه‌های عمرانی	محدوده شرکت	تأمین ایمنی	تأمین پایدار	برخوردااری	کارایی
آذربایجان شرقی	0/151961	0/285015	1/465544	0/261251	0/866124	0/824466	0.219958	0.909573
آذربایجان غربی	0/097079	0/165613	0/362091	0/128305	0/91324	0/73265	0.102944	0.927879
اردبیل	0/079522	0/148141	0/119022	0.157386	0/472788	0/741676	0.121852	0.832081
اصفهان	1	1	0/493605	0.519921	0/878983	0/929296	0.452528	0.927466
تهران	0/184441	0/31707	0/782852	0.536001	0/483944	0/8761	0.46752	0.961674
تهران بزرگ	0/823541	0/814416	1	1	0/90584	0/820579	1	1
خراسان رضوی	0/808623	0/870643	0/759235	0/411462	0/978034	0/877507	0.419331	0.946083
خوزستان	0/671408	0/695324	0/352342	0/232753	0/922379	0/991879	0.199683	0.941041
زنجان	0/071322	0/128618	0/156055	0/103745	0/943019	0/857725	0.084662	0.974132
سمنان	0/084535	0/147625	0/074353	0/081416	0/966415	0/893237	0.063354	0.997571
فارس / بوشهر	0/291089	0/417055	0/394025	0/327627	0/731032	0/848586	0.283059	0.910125
قم	0/094973	0/151514	0/077439	0/02204	0/929274	0/85571	0.020698	1
لرستان	0/067892	0/132115	0/117332	0/086278	0/984311	0	0.073154	0.904709
مازندران	0/426245	0.462317	0/364772	0/442496	0/88364	0/888732	0.335573	0.943103
مرکزی	0/106704	0/189685	0/166614	0/154913	0/920275	0/904788	0.134179	0.973695
همدان	0/179174	0/267141	0/207242	0/154671	0.440618	0/823697	0.133836	0.845801
یزد	0/061758	0/120223	0/111185	0/084845	0/940662	0/990391	0.075416	1
چهارمحال و بختیاری	0/173029	0/207278	0/120125	0/102	0/9876	0/928995	0.088203	0.989729
کردستان	0/056881	0/140144	0/208938	0/124202	0/966708	1	0.102079	1
کرمان	0/088706	0/159226	0/418065	0/035847	0/899297	0/910329	0.030498	0.934493
کرمانشاه	0/073748	0/137062	0/408573	0/14602	0/804894	0/910329	0.122919	0.938295
گلستان	0/160501	0/231717	0/158351	0/155016	1	0/779496	0.137218	0.991558
گیلان	0/213297	0/314766	0	0/15312	0/418369	0/920897	0.125747	0.889911

جدول 3: مقادیر عوامل اشاره شده در فرمول‌های نرمال سازی داده‌ها در سال 85

	هزینه پرسنلی	هزینه غیر پرسنلی	هزینه‌های عمرانی	محدوده شرکت	تأمین ایمنی	تأمین پایدار	برخوردااری	کارایی
MAX	106396	189521	2227423	3562182	93/67685	111.8478	3147894	100
MIN	7631	18616	68043	30571	20/48662	78/28025	23949	80/05729
m	8/77E-06	4/8E-06	4/36E-07	2/78E-07	0/008759	0/00526	3/15E-07	0/005554
b	0/066923	0/089441	0/029642	0/008509	0/17945	0/411724	0/00755	0/444621

جدول 4: داده‌های نرمال شده واحدها به همراه کارایی محاسبه شده با مدل DEA در سال 85

کارایی	برخورداری	تأمین پایدار	تأمین ایمنی	محدوده شرکت	هزینه‌های عمرانی	هزینه غیر پرسنلی	هزینه پرسنلی	واحد
0/890456	0/146456	0/888409	0/814463	0/191426	1	0/505186	0/312259	آذربایجان شرقی
0/949268	0/160809	0/823448	0/840873	0/223658	0/176145	0/264504	0/190209	آذربایجان غربی
0/990446	0/111706	0/918062	0/893161	0/147678	0/085543	0.250513	0/195357	اردبیل
0/920116	0/483942	0/941369	0/791466	0/558016	0/216784	1	0/927789	اصفهان
1	0/465394	0/955346	0/806403	0/639614	0/341842	0/496591	0/369579	تهران
1	1	0/909594	0/983569	1	0/458384	0/936076	1	تهران بزرگ
0/936706	0/444013	0.89685	0/879413	0/459677	0/479974	0/820849	0/613688	خراسان رضوی
0/901312	0/181788	1	0/834535	0/26888	0/345508	0/858896	0/838187	خوزستان
0/982605	0/070348	0/923172	0/880826	0/091659	0/125059	0/210602	0/161602	زنجان
0/990058	0/049773	0/904874	0/851388	0/052365	0/061315	0/231276	0/170591	سمنان
0/918659	0/26039	0/901921	0/868062	0/295059	0/288561	0/600979	0/593193	فارس / بوشهر
1	0/017678	0/944193	0/823038	0/017754	0/063071	0/229459	0/193042	قم
0/96365	0/081778	0/899948	0/842673	0/102404	0/079182	0/221666	0/155612	لرستان
0/92639	0/296097	0/906093	0/787337	0/408629	0/174211	0/492253	0/414209	مازندران
0/97732	0/153478	0/937685	0/850684	0/154418	0/089806	0/328562	0/226832	مرکزی
0/889242	0/124857	0/823671	0/806379	0/152525	0/118571	0/422688	0/354732	همدان
1	0/076528	0/981085	0/866587	0/093655	0/080824	0/178882	0/133845	یزد
0/897003	0/073914	0/93876	0/3589	0/089285	0/059285	0/214109	0/156086	چهارمحال و بختیاری
0/988563	0/092461	0/923967	0/869999	0/103083	0/126519	0/225505	0/140502	کردستان
0/954995	0/015101	0/943651	0/86217	0/017018	0/136696	0/297343	0/210336	کرمان
0/963844	0/122269	0/949119	0/874533	0/693519	0/155827	0/236637	0/161374	کرمانشاه
0/945329	0/124736	0/920879	0/813817	0/132505	0/106773	0/282391	0/222184	گلستان
0/971595	0/120004	0/916647	1	0/196981	0/150326	0/4938	0/436125	گیلان


m : تعداد ورودی‌های هر DMU

$$n > 3(s+m)$$

s : تعداد خروجی هر DMU و n : تعداد DMUها

برای رفع این مشکل از سال‌های مختلف (84 و 85) می‌توان به عنوان DMUهای متفاوت استفاده کرد و تعداد DMUها را به 46 واحد افزایش داد. در این صورت تحلیل کارایی واحدها بر اساس میانگین داده‌ها با مدل CCR ورودی محور به صورت جدول (6) خواهد بود:

همان‌طور که ملاحظه می‌شود DEA قادر به تفکیک کارایی همه شرکت‌ها از یکدیگر نیست. دلیل این موضوع واضح است، زیرا تعداد واحدهای تصمیم‌گیرنده نسبت به تعداد ورودی‌ها و خروجی‌ها کم است. هر چه این نسبت بیشتر باشد، مدل قدرت تفکیک‌پذیری بالایی خواهد داشت. در صورتی که این رابطه تجربی بین تعداد DMUs و ورودی‌ها و خروجی‌ها برقرار باشد، قدرت تفکیک‌پذیری مدل مناسب است:



شکل 7: گام‌های الگوریتم تحلیل کارایی با استفاده از Neuro-DEA

جدول 5: کارایی واحدها در سال‌های 84 و 85 با مدل DEA

واحدها	کارایی در سال 84	کارایی در سال 85
آذربایجان شرقی	0/910	0/890
آذربایجان غربی	0/928	0/949
اردبیل	0/832	0/990
اصفهان	0/927	0/920
تهران	0/962	1/000
تهران بزرگ	1/000	1/000
خراسان رضوی	0/946	0/937
خوزستان	0/941	0/901
زنجان	0/974	0/983
سمنان	0/998	0/990
فارس / بوشهر	0/910	0/919
قم	1/000	1/000
لرستان	0/905	0/964
مازندران	0/943	0/926
مرکزی	0/974	0/977
همدان	0/846	0/889
یزد	1/000	1/000
چهارمحال و بختیاری	0/990	0/897
کردستان	1/000	0/989
کرمان	0/934	0/955
کرمانشاه	0/938	0/964
گلستان	0/992	0/945
گیلان	0/890	0/972

جدول 6: کارایی واحدها بر اساس میانگین داده‌ها در سال‌های 84 و 85

واحدها	کارایی واحدها بر اساس میانگین داده‌ها در سال‌های 84 و 85
آذربایجان شرقی	54/9
آذربایجان غربی	78/8
اردبیل	74/7
اصفهان	50/8
تهران	100
تهران بزرگ	93/9
خراسان رضوی	31/1
خوزستان	16/7
زنجان	84/1
سمنان	100
فارس/بوشهر	46/1
قم	100
لرستان	100
مازندران	58/8
مرکزی	71/9
همدان	35/6
یزد	100
چهارمحال و بختیاری	83
کردستان	100
کرمان	93/1
کرمانشاه	98/5
گلستان	56/9
گیلان	70/2

LM، در واقع همان کارایی داده‌ها در سال جدید یعنی سال 85 است که به شکل جدول (7) است:

قابل ذکر است که در الگوریتم یادگیری گرادیان مزدوج (SCG) از شبکه‌ای با 18 نرون در لایه میانی و در الگوریتم یادگیری لوبنبرگ-مارکواد (LM) از شبکه‌ای که شامل 12 نرون در لایه میانی است، استفاده شده است و خروجی هر دو شبکه (کارایی واحدها) با کارایی محاسبه شده از طریق مدل DEA در جدول شماره 7 مقایسه شده است. شبکه پس از حدود صد تکرار با خطای اندکی الگوی کارایی را یاد می‌گیرد. خطای یادگیری برای این شبکه به مطابق شکل (8) است.


نتایج حاصل از شبکه قدرت تفکیک‌پذیری مناسبی از شبکه عصبی را نشان می‌دهد. شکل‌های (9) و (10) مقایسه خروجی محاسبه شده توسط DEA با SCG و LM را نشان می‌دهد.

با محاسبه کارایی شرکت‌ها در سال‌های مختلف، همچنان مشکل تعیین مرز کارایی برای همه واحدها پابرجا است و مدل‌های پایه‌ای DEA، قابلیت تحلیل کارایی در این مورد را ندارند. بنابراین در این مقاله بر آن شدیم تا از شبکه‌های عصبی و توانایی آن‌ها در پیش‌بینی، تقریب روابط و توابع غیر خطی کمک بگیریم و به تحلیل کارایی بپردازیم. بدین منظور از یک شبکه عصبی پیش‌بینی‌کننده عملکرد برای این مورد بر اساس توپولوژی شبکه و دو الگوریتم یادگیری که در قبل بیان شده است، استفاده می‌شود. در اینجا داده‌های نرمال واحدهای تصمیم‌گیرنده در سال 84 به همراه کارایی محاسبه شده با DEA به شبکه آموزش داده می‌شود. شبکه پس از چند تکرار با خطای اندکی الگوی کارایی واحدها را یاد گرفته و یک نگاشت غیرخطی بین ورودی‌ها و خروجی برقرار می‌کند. خروجی محاسبه شده از طریق شبکه عصبی پیش‌بینی‌کننده با دو الگوریتم یادگیری SCG و


جدول 7: مقایسه کارایی (خروجی) محاسبه شده با مدل DEA و شبکه‌های عصبی پیش بینی کننده

با الگوریتم‌های یادگیری SCG و LM


واحد	شرکت گاز استانی	خروجی DEA	خروجی شبکه با الگوریتم SCG	خروجی شبکه با الگوریتم LM
1	آذربایجان شرقی	0/890	0/882	0/882
2	آذربایجان غربی	0/949	0/951	0/948
3	اردبیل	0/990	0/978	0/986
4	اصفهان	/920	0/935	0/929
5	تهران	1/000	0/984	0/995
6	تهران بزرگ	1/000	0/992	0/999
7	خراسان رضوی	0/937	0/961	0/936
8	خوزستان	0/901	0/880	0/901
9	زنجان	0/983	0/973	0/988
10	سمنان	0/990	0/987	0/993
11	فارس / بوشهر	0/990	0/932	0/929
12	قم	1/000	0/998	0/996
13	لرستان	0/964	0/971	0/969
14	مازندران	0/926	0/938	0/936
15	مرکزی	0/977	0/974	0/979
16	همدان	0/889	0/905	0/887
17	یزد	1/000	0/992	0/992
18	چهارمحال و بختیاری	0/897	0/881	0/891
19	کردستان	0/989	0/974	0/983
20	کرمان	0/955	0/967	0/956
21	کرمانشاه	0/964	0/971	0/962
22	گلستان	0/945	0/962	0/944
23	گیلان	0/972	0/967	0/972



شکل 8: رفتار خطای شبکه



شکل 9: نمودار مقایسه ای خروجی (کارایی) محاسبه شده توسط DEA و SCG



شکل 10: نمودار مقایسه ای خروجی (کارایی) محاسبه شده توسط DEA و LM

پایه‌ای DEA توانایی تحلیل کارایی را به تنهایی ندارند. بنابراین از شبکه‌های عصبی استفاده شد. نتایج تحقیق نشان داد که شبکه‌های عصبی، توان بالایی در یادگیری الگوهای کارایی دارند، اما لازم به ذکر است که شبکه باید به شکل مناسبی آموزش داده شود. با استفاده از شبکه‌های عصبی و تلفیق آن با DEA می‌توان در مواردی که مدل‌های پایه‌ای توان تفکیک‌پذیری و تشخیص واحدها را ندارند به کار گرفت. در مقایسه انجام‌گرفته با روش‌های ریاضی و ترکیبی تحلیل کارایی، شبکه‌های عصبی نتایج قابل قبولی ارائه دادند.

در حال حاضر در شبکه Neuro-DEA نیاز است که از مدل‌های پایه‌ای DEA نیز استفاده شود. در تحقیقات بعدی قصد داریم روی این موضوع مطالعات وسیع‌تری انجام دهیم و از شبکه‌های محاسبه‌کننده کارایی و همچنین از شبکه‌های خودسازمان‌ده استفاده کرده و شبکه‌ای ساخته شود که به طور کامل مستقل از DEA کارایی را تحلیل کند.

نتایج حاصل، نشان‌دهنده قدرت بالای تفکیک‌پذیری نمره کارایی واحدها در این مدل است. خروجی محاسبه‌شده شبکه با الگوریتم SCG شرکت گاز استان قم با درصد کارایی 99/8 را کارآترین واحد و شرکت گاز استان خوزستان با درصد کارایی 88 را ضعیف‌ترین واحد از نظر عملکرد ارزیابی کرده است. الگوریتم LM نیز شرکت گاز استان تهران بزرگ را با درصد کارایی 99/9 بالاترین و آذربایجان شرقی با درصد کارایی 88/2 را پایین‌ترین واحد از نظر کارایی محاسبه می‌کند. شایان ذکر است که این الگوریتم نیز شرکت گاز قم را به عنوان واحدی با درصد کارایی بالا یعنی 99/6 و شرکت گاز خوزستان را به عنوان شرکتی با درصد کارایی پایین یعنی 90/1 محاسبه می‌کند.

نتیجه‌گیری و پیشنهاد برای تحقیقات بعدی

در این پژوهش در یک مطالعه موردی در ارزیابی عملکرد شرکت‌های گاز استانی ملاحظه شد که مدل‌های

مراجع

- 1- Mehregan, M., Farasat, A. and Kamyab Moghadas, A. (2006). "Analysis of the technical efficiency of the Iranian petroleum refinery using of the synthetic model of Neural Networks, and Data Envelopment Analysis(DEA)." *Human and Social Science journal*, 6th year, 23th No.
- 2- Mehregan, M. (2004). "Quantitative models in evaluating organizations performance (DEA)." Published by Faculty.
- 3- Delgado, F.J. (2005). "Measuring efficiency with neural networks: an application to the public sector." *Economics Bulletin*, Vol. 3, No.15, PP. 1-10.
- 4- Wu, D, Yang, Z and Liang, L. (2005). "Using DEA-neural network approach to evaluate branch efficiency of a large Canadian Bank." *Expert System with Application*, PP. 1-8.
- 5- Bauer, P.W(1990). "Recent developments in the econometric of frontiers." *Journal of Econometrics*, 46, PP. 39-56.
- 6-Wang, S.(2003). "Adaptive non-parametric efficiency frontier analysis: Aneural network-based model." *Computers and Operation Research*, 30, PP. 279-295.
- 7- Casta, A. and Harkellas, R.N(1997). "Evaluating public transport efficiency with neural network models." *Transportation research*, c 5, PP. 301-312.
- 8- Fleissing A. Kaston R., Terrel (2000). "Evaluating the semi-nonparametric fourier, aim, and neural networks cost function." *Economics Letter*, 68(3), PP. 235-244.
- 9- Santin, D. and Delgado, F.J. (2004). "The measurement of rechnical efficiency: a neural network approach." *Applied Economic*, 36, PP. 627, 635.
- 10- Celebi, D. and Bayraktar, D. (2007). "An integrated neural network and data envelopment analysis for supplier evaluation under incomplete information." *Expert Systems With Applications*, PP. 1-13.
- 11- Neto, Luiz.E. and Lins Marcos, P.E (2004). "Neural data envelopment analysis: A simulation." *International Journal of Industrial Engineering*, Vol. 11, No. 1, PP. 14-24. of management of Tehran University, 1st Edition.
- 12- Cattoufi, S. and Muhittin, O. (2005) Data envelopment Analysis Literature: a bibliography Update, Saio-Economic planning sciences, 38, PP. 159-229.
- 13- Amirteimoori, H. (2004). "Measurment efficiency of gas companies using DEA." Thesis of Master in Industrial Engineering, Islamic Azad University, Arak Branch.
- 14- Menhaj, M. (2005). *Neural Networks Basics*, 1st Volume, Published by Amirkabir University, 3rd Edition, Tehran
- 15- Menhaj, M. (2006). *Neural Networks Basics*, 1st Volume, Published by Amirkabir University, 3rd Edition, Tehran
- 16- Shalkef, G.r. (2003). *Artificial Neural Networks*, Published by Chamran Ahvaz University, 1st Edition.
- 17- Vellido, A., Liboa, P.J.G. and Vaughan, J., (1999). "Neural networks in business: a survey of applications." *Expert Systems with Application*, 17, PP. 51-70.
- 18- Gupta, N.D. and Smith Kate, A. (2000) "Neural networks in business: techniques and applications for the operations researcher." *Computers & Operations Research*, 27 , PP. 1023-1044.
- 19- Troutt, M.D , Rail, A. and Zhang, A. (1995), "The potential use of DEA for credit applicant acceptance system." *Computers and Operation research*, 4, PP. 405-408.

- 20- Athnossopulos, A. and Curram, S. (1996) "A comparison of data envelopment analysis and artificial neural networks as tool for assessing the efficiency of decision making units." *Journal of the Operation Research Society*, 47 , PP. 1000-1016.

واژه‌های انگلیسی به ترتیب استفاده در متن

- 1- Artificial Intelligence (AI)
- 2- Feed Forward Networks
- 3- Recurrent Networks
- 4- Unsupervised Learning
- 5- Supervised Learning
- 6- Self-Organize
- 7- Backpropagation
- 8- Multi layer Perceptron (MLP)
- 9- Global Approximator
- 10- Feedforward
- 11- Tanh
- 12- Conjugate Gradient Algorithms
- 13- Scaled Conjugate Gradient
- 14- Quasi-Newton Algorithms
- 15-Levenberg-Marquardt (LM)

Archive of SID