

مدل سازی رفتار مصرف کننده محصولات بسته بندی فرنگی در سازمان مدیریت میادین میوه و تره بار تهران با استفاده از شبکه عصبی مصنوعی

آریا هوشمندان^۱ و ولی بریم نژاد^۲

چکیده

کشش‌های تقاضا برای سیاست‌گذاری بسیار مهم می‌باشند. تولیدکنندگان، واحدهای فرآوری و خرده فروش‌ها نیاز به مدل سازی و پیش بینی تقاضا برای برنامه‌ریزی در تولید و فروش را داشته و کشش تقاضای محصولات نقش مهمی در این خصوص دارند. ضرورت انجام این تحقیق، کمبود مطالعه در برآورد تقاضا و مدل سازی آن توسط شبکه عصبی مصنوعی در ادبیات اقتصادی است. در این تحقیق نسبت به برآورد تقاضا و کشش‌های قیمتی محصولات بسته بندی با توجه به داده‌های مقطعی با استفاده از شبکه عصبی در نرم افزار متلب 2011a اقدام شده است. قابل ذکر است که متغیرهای دموگرافیک اجتماعی به همراه متغیرهای اقتصادی مثل قیمت و درآمد می‌توانند انتخاب مصرف کننده را تحت تأثیر قرار دهند. برخلاف اغلب مدل‌های پارامتریک کلاسیک، شبکه عصبی مصنوعی غیر پارامتریک بوده و بسیار انعطاف پذیر است و این انعطاف پذیری ناشی از قابلیت شبکه عصبی مصنوعی در حل روابط غیر خطی پیچیده بین متغیرهای ورودی و خروجی در یک سیستم است. در این مقاله رفتار مصرف کننده محصولات فرنگی بسته بندی در بازار سازمان مدیریت میادین میوه و تره بار تهران بررسی و منحنی تقاضا و کشش‌های آن توسط شبکه عصبی چند لایه پیشخور^۳ تخمین زده شده است.

طبقه بندی JEL: Q11, C14, C45

واژه‌های کلیدی: مدل سازی، شبکه عصبی مصنوعی، تقاضا، کشش

مقدمه

شبکه‌های عصبی جزء گروه مدل‌های داده- ستاده محسوب شده که بوسیله دانشمندان علوم شناختی^۴ ایجاد شده‌اند. این مدل‌ها، قابلیت یادگیری و حفظ دانش از درون اطلاعات نمونه را دارند و می‌توانند از روی شواهد و قرائن و خارج از اطلاعات نمونه پیش‌بینی نمایند. شبکه‌های عصبی به طبقه مشخصی از روش‌های پارامتریک غیرخطی منسوب می‌شوند. "یادگیری" در شبکه عصبی معادل تخمین آماری پارامترهای مدل در اقتصادسنجی است (کائن و همکاران، ۱۹۹۴). شبکه‌های عصبی بعنوان ابزار محققین در بسیاری از زمینه‌ها به مانند پردازش سیگنال (سجنوسکی و همکاران، ۱۹۹۰؛ مالکوف، ۱۹۹۰)، تشخیص دست‌خط

به ترتیب^۱ - آریا هوشمندان دانشجوی کارشناسی ارشد اقتصاد کشاورزی، دانشگاه آزاد اسلامی، واحد کرج

^۲ - ولی بریم نژاد دانشیار دانشگاه آزاد اسلامی، واحد کرج

Arya773@yahoo.com

^۳ - Multilayer Feedforward Artificial Neural Network

^۴ علوم شناختی (Cognitive Science) پژوهش علمی درباره ذهن و مغز تعریف می‌شود، شاخه‌ای میان رشته‌ای است که از رشته‌های مختلفی مانند روان‌شناسی، فلسفه ذهن، عصب‌شناسی، زبان‌شناسی، انسان‌شناسی، علوم رایانه و هوش مصنوعی تشکیل شده است. این علم به بررسی ماهیت فعالیت‌های ذهنی مانند تفکر، طبقه‌بندی و فرآیندهای که انجام این فعالیت‌ها را ممکن می‌کند، می‌پردازد (دائرةالمعارف بریتانیکا).

(لی کان و همکاران، ۱۹۹۰)، تشخیص اثر انگشت (لیانگ و همکاران، ۱۹۹۰)، پیش‌بینی ورشکستگی بانک‌ها (آلتمن و همکاران، ۱۹۹۴)، پیش‌بینی فعالیت‌های مالی بورس (آزوف و همکاران، ۱۹۹۴؛ گیتلی، ۱۹۹۶؛ تریپاند و همکاران، ۱۹۹۳)، مدل‌سازی و پیش‌بینی موارد اقتصادی (جوردینگ و همکاران، ۱۹۹۴؛ معصومی و همکاران، ۱۹۹۴؛ فدراستون، ۱۹۹۶؛ تراسویرتا و همکاران، ۲۰۰۴؛ گاوپدیا و همکاران، ۲۰۰۴) بوده‌اند.

دلیل اینکه چرا محققین رشته‌های مختلف علاقه‌مند به استفاده از مدل‌های شبکه عصبی در تحقیقات خود بوده‌اند را می‌توان در ماهیت شبکه‌های عصبی دانست که به عدم وابستگی آن‌ها به فرضیات محدودکننده مانند خطی بودن (در اغلب موارد برای استفاده از مدل‌های ریاضی کلاسیک ضروری می‌باشد) مربوط است (مشیری، ۱۹۹۸) اگرچه شبکه عصبی مقبولیت عام دارد اما کاربرد شبکه‌های عصبی متفاوت بوده و این بدان معنی است که همه افراد از شبکه‌های عصبی به یک شکل استفاده نمی‌کنند. برای مثال، متخصصین اعصاب^۱ ممکن است از این مدل‌ها به عنوان مدل‌هایی برای تشریح داده‌های بیولوژیکی استفاده کنند، دانشمندان علوم رایانه به آنها بعنوان زیر مجموعه هوش ماشینی نگاه می‌کنند (وییس و همکاران، ۱۹۹۱)، متخصصین آمار از شبکه‌های عصبی بعنوان مدل‌های رگرسیون غیرخطی و طبقه‌بندی و یا به عنوان مدل‌های غیرپارامتریک بهمراه دیگر ابزارهای سنتی استفاده می‌نمایند (وایت، ۱۹۸۹؛ بیشاپ، ۱۹۹۵؛ سارله، ۱۹۹۴)، مهندسی و دیگر محققین در کاربردهایی که به فرآیندهای غیرخطی در داده‌های پیوسته و یا توابع شبیه‌ساز نیاز است (فاناهاشی، ۱۹۸۹) و در تجزیه و تحلیل داده‌های کوانتوم از شبکه‌های عصبی برای یافتن الگوهایی در میان انبوه داده‌ها، بعنوان یک سیستم اطلاعاتی یا مکانیزم‌های یادگیری دانش و سیستم‌های پشتیبان از تصمیم‌سازی (بیگوس، ۱۹۹۶) استفاده می‌کنند. بطور خلاصه، افراد چه دانشگاهی و چه متخصصین صنعتی از شبکه عصبی بعنوان ابزاری کارآمد و کاربردی استفاده می‌نمایند، اگرچه ماهیت کاربردی آن متفاوت است. کاربرد موفق مدل‌های شبکه‌های عصبی در زمینه‌های مختلف می‌تواند ابزاری مفیدی در اقتصاد باشد (کائن و همکاران،

۱۹۹۴). از جنبه متدولوژی، در اقتصاد مطالعات به دو دسته رگرسیون و طبقه‌بندی تقسیم می‌شوند (گجراتی، ۱۹۹۵؛ گرین،

۱۹۹۷). در رگرسیون بیشترین مباحث مورد مطالعه به رگرسیون‌های خطی برمی‌گردد و روش اصلی برای تخمین پارامترها روش حداقل مربعات است. در طبقه‌بندی مدل‌های لاجیت^۳، پروبیت^۴ و مدل‌های احتمالات خطی^۵ بطور معمول بکار گرفته می‌شوند و از مدل‌های پیچیده‌تر مثل مدل‌های معادلات همزمان برای حل مسائل اقتصادی در دنیای واقعی استفاده می‌گردد. هدف نهایی همه این مطالعات، درک قوانین اصلی حاکم بر پدیده‌های اقتصادی است.

در هر حال اعتبار نتایج و دست‌آوردهای تحقیقاتی ما، وابسته به فروض زیادی می‌باشد. در ابتدا برای ساده‌سازی و راحتی شاید ترجیح دهیم که روابط بین متغیرهای وابسته و مستقل را خطی در نظر بگیریم (گجراتی، ۱۹۹۵؛ گرین، ۱۹۹۷). در حقیقت، این فرض خطی بودن روابط شاید در عالم واقع فرض درستی نباشد چون پدیده‌های اقتصادی از نوع سیستم‌های پویا (عوامل تداخلی) بوده و مدل‌های خطی نمی‌توانند بطور دقیق بیان‌کننده پدیده‌های اقتصادی باشند. در ضمن، این مدل‌ها اغلب نتایج غیردقیقی را به دست می‌دهند. حتی اگر مدل‌های غیرخطی برای الگوهای اقتصادی ارائه گردد، باید بعضی از فروض به مدل اعمال شوند. وقتی سیستم‌های اقتصادی پیچیده‌تر شوند و یا الگوهایی عرضه و تقاضا در ارتباط با کنش و واکنش رفتار هر فرد

1 - Neurologist
2 -Data-Mining
3 -Logit
4 -Probit
5 -LPM

مطرح شوند، تعیین مدلی که بتواند تمام فاکتورهای مؤثر در ارتباط با کنش‌ها و واکنش‌ها را در برداشته باشد اگر نگوئیم غیرممکن، بسیار دشوار خواهد بود. چنین پیچیدگی باعث می‌شود که تلاش برای تقریب مدل‌هایی مانند حداکثرسازی مطلوبیت یا سود با این جزئیات غیرممکن بنظر رسد. در این جاست که مدل‌های شبکه‌عصبی می‌توانند نقش ایفا نموده و نسبت به ارزیابی یا شبیه‌سازی پدیده‌های اقتصادی یا اجتماعی عمل نمایند. این دقیقاً همان چیزی است که متدولوژی شبکه‌عصبی قادر به انجام آن هستند (شاکمورف، ۲۰۰۴) و بالاخره اعتبار بهترین، خطی و بدون تورش بودن تخمین زنده‌ها^۱ در روش حداقل مربعات، بستگی به فروض توزیع نرمال با میانگین صفر، همسانی واریانس، عدم همبستگی در جملات اخلال و ... دارد (گجراتی، ۱۹۹۵؛ گرین،

۱۹۹۷). بهر حال این فروض می‌تواند در عمل درست یا نادرست باشند. اگرچه روش شبکه‌عصبی بومی علوم اقتصادی نیست اما

قادر است موضوعات اقتصادی را مدل‌سازی نماید. این روش، در اقتصاد و اقتصادسنجی از اواخر دهه ۸۰ میلادی با مطالعه وایت در بازارهای مالی، پیش‌بینی قیمت سهام شرکت IBM آغاز شد (وایت، ۱۹۸۸). پس از وایت مطالعات متعددی در زمینه کاربرد شبکه‌مصنوعی با موفقیت صورت پذیرفت اما موفقیت شبکه‌های عصبی در حوزه اقتصادی مالی، توجه متخصصان اقتصاد کلان و اقتصادسنجی را به خود جلب نمود و استفاده از شبکه‌های عصبی در پیش‌بینی از دهه ۹۰ آغاز شد (قدیمی و همکاران، ۱۳۸۱). مطالعات دیگری در پیش‌بینی متغیرهای مختلف اقتصادی صورت گرفت که از آن جمله می‌توان به مطالعه کهزادی و دیگران اشاره نمود در این پژوهش‌ها، پیش‌بینی قیمت سلف ذرت برای ده هفته آتی بر اساس قیمت‌های هفتگی صورت پذیرفت (کهزادی و همکاران، ۱۹۹۵). پورتگال دقت پیش‌بینی تولید ناخالص بخش صنعت در برزیل را با استفاده از شبکه‌های عصبی انجام داد (پورتگال، ۱۹۹۵). کهزادی و همکاران با استفاده از شبکه‌عصبی مصنوعی پیشخور نسبت به پیش‌بینی قیمت گندم و گاو زنده اقدام نمودند (کهزادی و همکاران، ۱۹۹۵). مشیری و همکاران (۱۹۹۵). مشیری و همکاران نرخ تورم کانادا را با استفاده از شبکه‌های عصبی پیشخور، سه لایه و پایه شعاعی را بررسی نمودند (مشیری و همکاران، ۱۹۹۹). تکاز با استفاده از شبکه‌عصبی مصنوعی رشد تولید ناخالص داخلی کشور کانادا را پیش‌بینی نمود (تکاز، ۲۰۰۱). اولسون و همکاران بر خلاف سایر مطالعات قبلی از شبکه‌عصبی علاوه بر پیش‌بینی در گروه‌بندی بازارهای مالی نیز استفاده نمودند و نشان دادند که شبکه‌های عصبی توانایی بیشتری در شناسایی روابط غیرخطی بین متغیر وابسته و مستقل دارد و لذا پیش‌بینی دقیق‌تر است (اولسون و همکاران، ۲۰۰۳). هیراوی و همکاران، توانایی شبکه‌عصبی مصنوعی در فرآیند خود رگرسیو در پیش‌بینی تولیدات صنعتی سه کشور اروپایی آلمان، فرانسه و انگلیس را مورد مقایسه قرار دادند (هیراوی و همکاران، ۲۰۰۴).

روش تحقیق

شبکه‌های عصبی مصنوعی الگوی بسیار ساده‌ای از دستگاه عصبی انسان و دارای قابلیت یادگیری بوده و با دریافت الگوهای ورودی^۲، قادر به استخراج مشخصات آن‌ها و نسبت دادن یک طبقه خاص به آن‌ها می‌باشند؛ به این ترتیب در خلال فرآیند آموزش آنها مشخصات الگوها و طبقه مورد نظر را با تطبیق دادن یک سری ضرایب وزنی به خاطر می‌سپارند. چنانچه آموزش به درستی صورت گیرد آنها قادر به طبقه‌بندی^۳ الگوها هستند (پولتون، ۲۰۰۱). برتری بزرگ شبکه‌عصبی، قدرت آن در مدل‌سازی روابط پیچیده غیرخطی، بدون نیاز به اعمال فرضیه‌های خاص در مورد رفتار متغیرها است و به مانند یک جعبه سیاه عمل

^۱ -Blue

^۲ -Input Pattern

^۳ -Classification

می‌کند (کارایانسیس و همکاران، ۱۹۹۳).

از منظر ریاضی، مجموع وزن‌ها بصورت ماتریسی است و این ماتریس، قدرت به حافظه سپردن دانش حاصل از داده‌های آموزش را داشته و مترادف ضرایب مدل در مدل‌های اقتصاد سنجی هستند. تابع تبدیل‌کننده، بخش اساسی یک شبکه عصبی است که شبیه تابع لجستیک در مدل‌های لاجیت و تابع معکوس در مدل خطی تعمیم‌یافته^۱ می‌باشد (مک کولاق و همکاران، ۱۹۸۹). تابع فعال‌ساز، نتیجه تابع جمع‌کننده را به خروجی مورد نظر، تبدیل می‌کند. برای مثال نورون می‌تواند برای این کار از تابع فعال‌ساز با خروجی ۰ و ۱ یا تابعی که خروجی آن بین ۱- و ۱+ است و یا توابع ترکیبی استفاده نماید. شبکه‌های عصبی پیشخور با یک لایه پنهان (تابع فعال‌ساز لجستیک) و یک تابع فعال‌ساز خطی در لایه خروجی و تعداد نورون کافی در لایه پنهان، کاربردی‌ترین نوع شبکه عصبی مصنوعی می‌باشند، چرا که قادرند هر تابع خطی و غیرخطی را با دقت دلخواه تقریب بزنند (کائون و همکاران، ۱۹۹۴) به همین علت به شبکه عصبی با ساختار فوق، تقریب‌زننده جامع^۲ می‌گویند. روش‌های آموزش شبکه عصبی شامل روش آموزش نظارت نشده^۳ و نظارت شده^۴ می‌باشد. در روش نظارت شده که در عمل بیشتر از آن استفاده می‌شود، پس از اعمال مجموعه‌های داده‌های آموزشی، پارامترهای شبکه به تدریج به سمت مقادیر نهایی خود نزدیک (همگرا) می‌شوند. تابع فعال‌ساز بکار رفته جهت تنظیم پارامترهای شبکه از نوع سیگموئید می‌باشد.

$$f(x) = \frac{1}{1+e^{-kx}} \quad (1)$$

طبق بررسی‌های بعمل آمده بهتر است سعی شود تا نرمال کردن داده‌ها به گونه‌ای صورت گیرد تا میانگین داده‌ها نزدیک به ۰/۵ باشد (کومار و همکاران، ۲۰۰۲).

$$X_{normal} = 0.5 \left[\frac{x_0 - \bar{x}}{x_{max} - x_{min}} \right] + 0.5 \quad (2)$$

در یک شبکه نظرات، جهت آموزش باید خروجی‌های y_i متناظر با هر الگوی ورودی تهیه شوند در این روش آموزش الگوهای خروجی واقعی t_i با خروجی محاسبه شده توسط شبکه y_i مقایسه شده و اختلاف آنها e می‌بایست با تغییر وزن‌های شبکه به کمک رابطه زیر کمینه شود. لازم بذکر است وزن‌های اولیه در شبکه به صورت تصادفی هستند.

$$e = \frac{1}{2} \sum_{i=1}^N (t_i - y_i)^2 \quad (3)$$

خطای e خطای محاسبه شده t_i ام الگوی ورودی می‌باشد. در یک شبکه با الگوریتم آموزشی پس انتشار خطا، ابتدا ورودی شبکه

بطور مستقیم در طول شبکه به منظور محاسبه خروجی شبکه جریان می‌یابد. چنانچه مقادیر خروجی شبکه با مقادیر خروجی واقعی در لایه خروجی متفاوت باشد با استفاده از خطای تعریف شده مقادیر تغییرات وزن ΔW_{ij} برای هر ضریب وزنی محاسبه و وزن‌ها با بازگشت این تغییرات در طول شبکه تصحیح می‌شوند. چگونگی تصحیح ضرایب وزنی به صورت زیر است (تورهان ۱۹۹۵):

$$\Delta W_{ij} = \alpha \frac{\partial e}{\partial W_{ij}} \quad (4)$$

¹ -GLM

² -Universal Approximator

³ -Unsupervised

⁴ -Supervised

که در آن ϵ یک کمیت مثبت و ثابت موسوم به نرخ یادگیری^۱ است که در واقع اندازه گام‌ها را در جهت دستیابی به کمینه خطا تنظیم می‌کند و انتخاب مناسب آن جهت عملکرد صحیح روش آموزش حیاتی است (منهاج ۱۳۷۹).

محاسبه کشش: بنا به تعریف، کشش خود قیمتی تقاضا برای کالای j ام عبارت است از نسبت نرخ تغییرات مقدار کالای j ام به نرخ تغییرات قیمت همان کالا در صورتیکه قیمت کالای j ام و درآمد ثابت باشد (هندرسون و همکاران، ۱۹۸۰). روش‌های کلاسیک برای تعیین کشش‌های قیمتی و درآمدی مستلزم تخمین توسط مدل‌های اقتصادسنجی است. رابطه بین قیمت و مقدار مصرف از نوع روابط متقابل، غیرخطی و دارای اثرات متقاطع غیرممتقارن می‌باشند و به همین منظور: الف) مدل‌هایی که دارای خصوصیات

مورد انتظار بیشتری هستند مانند مدل‌های AIDS و روتردام (دیتون و همکاران، ۱۹۸۰) و ب) روش جایگزین شبکه‌های عصبی مصنوعی که برای مدل‌سازی روابط پیچیده بسیار مناسب هستند؛ توسعه یافتند.

در ادبیات موضوع، پیشنهادات اندکی برای چگونگی محاسبه کشش‌ها در سیستم‌های غیرپارامتریک ارائه شده است. یکی از این روش‌ها توسط سابارائو و همکاران ارائه گردیده که به روش سابارائو^۲ معروف است (سابا و همکاران، ۱۹۹۸). در این روش، تعیین کشش بر اساس مشاهده احتمال تغییر در انتخاب هر فرد با توجه به تغییر در متغیر مربوطه انجام می‌شود و در طی مراحل ذیل انجام می‌پذیرد:

(۱) شبکه عصبی کالیبره شده و آموزش دیده با افزایش قیمت (درآمد) در درصدهای مختلف اجرا گردد.

(۲) داده‌های خروجی نرمالیز شده W_{ij} را برابر احتمال انتخاب فرد در نظر می‌گیریم.

(۳) عبارت W_{ij} بعنوان داده خروجی نرمالیز شده برای قیمت j ام بعد از درصد تغییر در قیمت کالای j ام

(۴) از معادله زیر برای محاسبه کشش سریالی انتخاب هر فرد براساس درصد تغییرات بین ۱٪ تا ۱۰۰٪

$$\epsilon_{ijk} = \frac{\frac{W_{ijk} - W_{ijk}^*}{W_{ijk}}}{\frac{P}{100}} \quad (5)$$

که j بعنوان متغیر ورودی تولید شده، i متغیر لایه پنهان تولید شده و k خروجی می‌باشد، استفاده می‌کنیم.

(۵) محاسبه میانگین احتمال وزنی هر کشش برای هر فرد و به دست آوردن مجموع کشش تقاضا.

این روش بدلائیل ذیل بسیار قدرتمند است:

الف) اجازه واکنش مصرف‌کننده به تغییرات مختلف قیمت را داده (برای تک‌تک خانوارهای موجود در نمونه) و کشش‌های انفرادی آن را محاسبه می‌کند.

ب) این امکان را به وجود می‌آورد که منحنی متوسط تقاضا توسط متوسط وزن هر کشش با توجه به تغییر در افزایش قیمت محاسبه گردد.

¹ -Learning rate

² -Subba Rao

کاربرد شبکه عصبی: در این مقاله، از نرم‌افزار متلب 2011a و شبکه عصبی چندلایه پیشخور با تابع فعال‌ساز سیگموئید لگاریتمی در لایه اول و دوم (دولایه پنهان)، تابع فعال‌ساز خطی در لایه خروجی، نوع آموزش نظارت‌شده و الگوریتم آموزش لیونبرگ-مارکوآت استفاده شده است. تعداد نورون‌ها در لایه پنهان اول ۸ و در لایه پنهان دوم ۳ می‌باشد. با توجه به این که هدف، مدل‌سازی جهت تخمین منحنی تقاضا است از داده‌ها تنها برای مراحل آموزش و آزمایش استفاده شده است و احتیاجی به مرحله ارزیابی نیست.

داده‌های مورد استفاده: جامعه تحقیق، مشتریان سه بازار سازمان مدیریت میادین میوه و تره‌بار تهران می‌باشند. داده‌های مورد نیاز از طریق پرسشگری از افراد بالای ۱۸ سال در فاصله زمانی دو هفته بدست آمده و شامل پرسش‌گری خریداران مربوط به رستوران‌ها، هتل‌ها و... نمی‌باشد. جهت تخمین اندازه نمونه، از فرمول ذیل با توجه به ماهیت جامعه، نوع بررسی و دقت مورد نظر استفاده می‌شود (ون دیلن، ۱۹۹۷).

$$S = \frac{X^2 NP(1-P)}{d^2(N-1)+X^2 P(1-P)} \quad (6)$$

با توجه به اندازه تقریبی جامعه مشتریان بازار (۳۵۰۰ نفر)، اندازه نمونه برابر با ۳۴۶ خواهد شد که در این تحقیق ۳۵۰ پرسشنامه تهیه گردید.

جدول (۱) مشخصات داده‌های تحقیق

نام متغیر	ماهیت متغیر	توضیحات	راهنما
جنسیت	کیفی	مرد / زن	Man / Woman
سن	کیفی	زیر ۳۰ سال / ۳۰ تا ۴۵ سال / ۴۵ تا ۶۰ سال / بالای ۶۰ سال	Age Group1 / Age Group2 / Age Group3 / Age Group4
تاهل	کیفی	متاهل / غیر متاهل	Married / Unmarried
تحصیلات	کیفی	زیردیپلم / لیسانس / بالای لیسانس	Education Group1 / Education Group2 / Education Group3
مناطق شهری	کیفی	شمال / جنوب / شرق / غرب	North / South / East / West
موقعیت شغلی	کیفی	شاغل / بیکار / بازنشسته / سایر	Employed / Unemployed / Retired / Misc
طبقه بندی سرانه	کیفی	۴۰۰ تا ۶۵۰ هزار تومان / ۶۵۰ تا ۹۰۰ هزار تومان / بالای ۹۰۰ هزار تومان	Income Group1 / Income Group2 / Income Group3 / Income Group4
درآمد	کیفی	بالای ۹۰۰ هزار تومان	price
قیمت	کمی	-	
میزان هزینه برای خرید کالا	کمی	-	

نتایج و بحث

تعداد تکرار^۱ مطلوب، بر اساس یک ترکیب پیش فرض و مقایسه مقادیر متفاوت شاخص‌های R^2 و MSE در ساختارهای متعدد شبکه عصبی مصنوعی صورت گرفت.

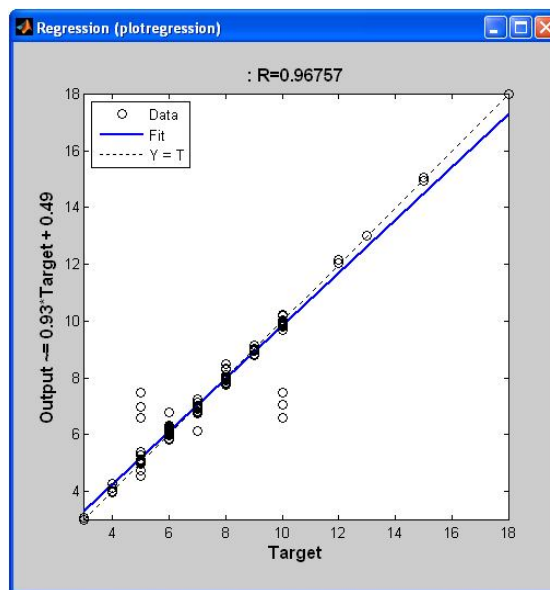
جدول (۲) مقادیر شاخص های شبکه عصبی مصنوعی

^۱ -Epoch


شاخص	مقادیر
Epoch	۱۰۰
R^2	۰/۹۶۷۵۷
MSE	۰/۳۹۶۳۶

مأخذ: یافته‌های تحقیق


رگرسیون کلی تقاضای محصولات فرنگی بسته‌بندی با توجه به کلیه متغیرهای سنتی (قیمت و درآمد) و متغیرهای دموگرافیک در نمودار (۱) نشان داده شده است:



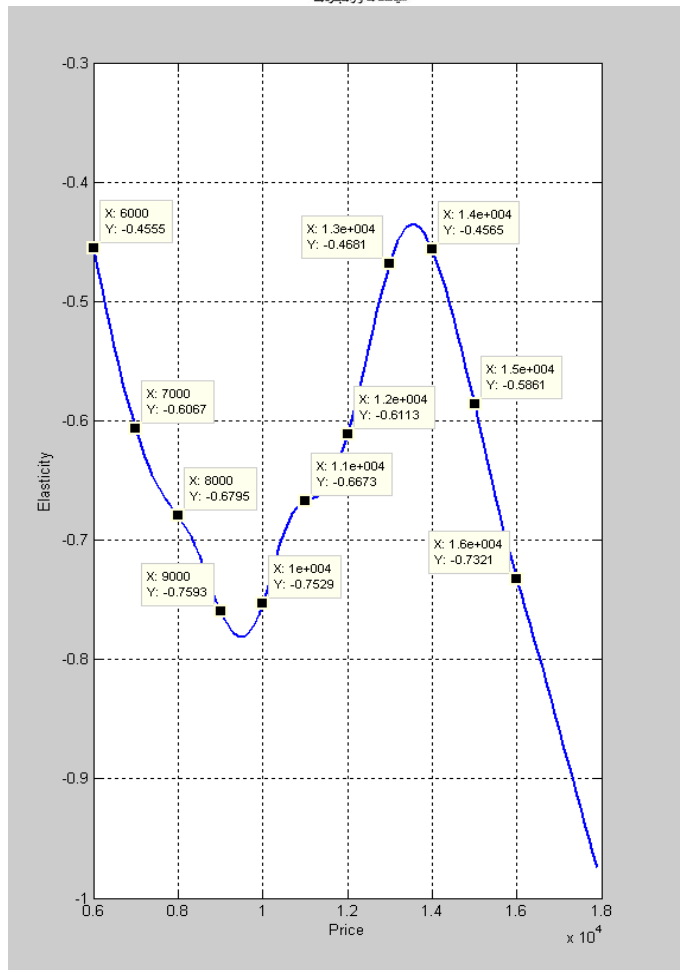
نگاره (۱): رگرسیون کلی



نگاره (۲): درصد فراوانی متغیرهای مختلف در نمونه



نگاره (۳): منحنی تقاضای کل محصولات فرنگی بسته‌بندی شده

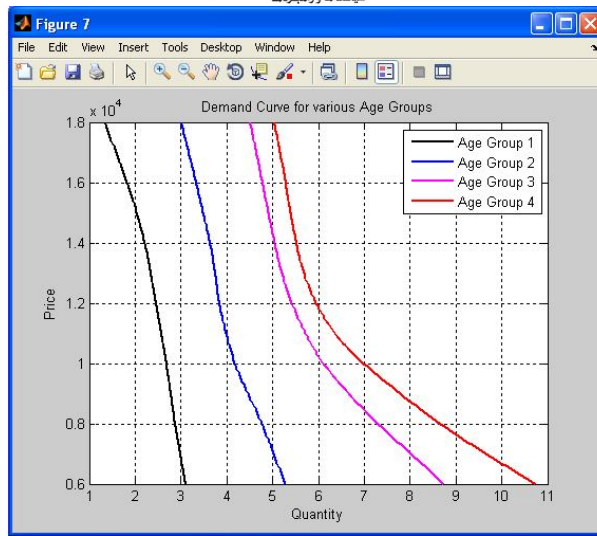


نگاره (۴): کشش خود قیمتی محصولات فرنگی بسته‌بندی در قیمت‌های مختلف


جدول (۳) مقادیر مختلف کشش خود قیمتی با توجه به تغییر قیمت

قیمت (تومان)	۱۶۰۰	۱۵۰۰	۱۴۰۰	۱۳۰۰	۱۲۰۰	۱۱۰۰	۹۰۰	۸۰۰	۷۰۰	۶۰۰
کشش	-۰/۷۳۲۱	-۰/۵۸۶۱	-۰/۴۵۶۵	-۰/۴۶۸۱	-۰/۶۱۱۳	-۰/۶۶۷۳	-۰/۷۵۹۳	-۰/۶۷۹۵	-۰/۶۰۶۷	-۰/۴۵۵۵


مأخذ: یافته‌های تحقیق




نگاره (۵): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر سن



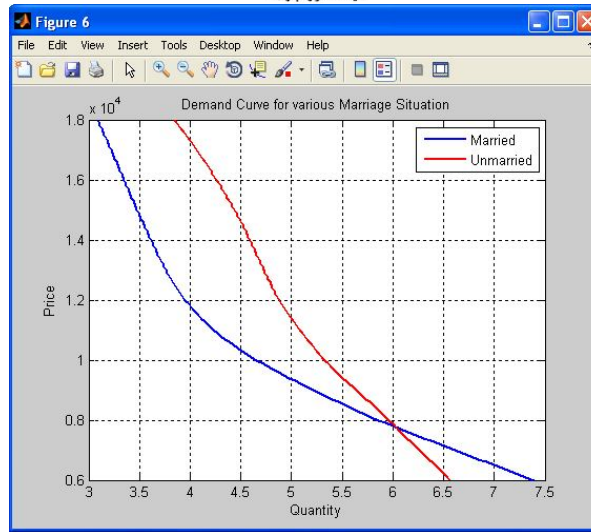
نگاره (۶): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به وضعیت شغلی




نگاره (۷): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر در آمد




نگاره (۸): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر مناطق شهری



نگاره (۹): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر وضعیت تاهل



نگاره (۱۰): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر جنسیت



نگاره (۱۱): منحنی تقاضای محصولات فرنگی بسته‌بندی شده با توجه به متغیر تحصیلات

نتیجه‌گیری و پیشنهاد

هدف اصلی این مقاله مدل‌سازی تقاضای محصولات فرنگی بسته‌بندی با استفاده از شبکه عصبی مصنوعی بجای روش‌های سنتی و پارامتریک بوده است. که با استفاده موفقیت‌آمیز از شبکه عصبی مصنوعی توانستیم نسبت به تخمین منحنی تقاضا و کشش خود قیمتی برای محصولات فرنگی بسته‌بندی در سازمان مدیریت میادین میوه و تره بار تهران اقدام نماییم. نکته قابل‌تأمل تغییرات کشش خود قیمتی در قیمت‌های متفاوت محصولات فرنگی بسته‌بندی می‌باشد. همانگونه که در جدول (۳) نشان داده شده کشش خود قیمتی در قیمت ۶۰۰ تومان برابر -0.4555 بوده که با افزایش قیمت تا قیمت ۹۵۰ تومان بر حساسیت قیمتی این کالا افزوده می‌شود و به عدد -0.7845 می‌رسد، اما بعد از قیمت ۹۵۰ تومان تا قیمت ۱۳۳۰ تومان مجدداً این کالا دارای حساسیت قیمتی کمتر و کمتر گردیده و به عدد -0.4441 رسیده و بعد از قیمت ۱۳۳۰ تومان مجدداً با افزایش بیشتر قیمت کالا به سمت کشش واحد پیش می‌رود.

این تغییر در نمودار (۳) منحنی تقاضا که در قیمت فوق منحنی روند عادی خود را طی نمی‌نماید نیز قابل‌رویت می‌باشد. در مجموع این تحقیق نشان می‌دهد که بعضی متغیرهای دموگرافیکی به‌همراه متغیرهای اقتصادی سنتی (قیمت و درآمد) انتخاب مصرف‌کننده را تحت‌تاثیر قرار می‌دهند که پیشنهاد می‌گردد در تقسیم‌بندی بازار و تعیین بازار هدف به آن توجه شود.

منابع

منهاج م. ب. (۱۳۷۹) مبانی شبکه عصبی مصنوعی: چاپ اول، انتشارات دانشگاه صنعتی امیرکبیر، تهران
قدیمی، م. ر. و س. مشیری (۱۳۸۱) مدل‌سازی و پیش‌بینی رشد اقتصادی ایران با استفاده از شبکه‌های عصبی مصنوعی، فصلنامه پژوهش‌های اقتصادی ایران، (۱۲): ۱۲۷-۹۵

- Altman, I. E. , Marco, G. and Varetto, F. (1994) Coporate distress diagnosis: comparisons using discriminant analysis and neural networks, *Journal of Banking and Finance*, 18:505-529
Azoff , F. M. (1994) Neural networks time series forecasting of financial markets, New York, Wiley
Bigus, J. J. (1996) Data mining with neural networks, Solving business problems from application development to decision support, New York
Deaton, A. , Muellbauer, J. (1980) An almost ideal demand system, *American economic review*, 70, 3:312-326

- Funahashi, K. I. (1989) On the approximate realization of continuous mapping by neural network, *Neural networks*, Vol. 2
- Green, H. W. (1997) *Econometrics analysis*, Prentice Hall, Inc.
- Gujarati, N. D. (1995) *Basic econometrics*, McGraw Hill, Inc., New York
- Henderson, J.M. , Quandt, R. E. (1980) *Microeconomics theory: Mathematical approach*, 79-22064
- Heravi S., Osborn, D. and Birchenhall R. (2004) Linear versus neural network forecasts for European industrial production series: *International Journal of Forecasting*, 20:435-446.
- Joerding, W., Li, H. Y. and Young, D. L. (1994) Feedforward neural network estimation of a crop yield response function: *Journal of Agricultural and Applied Economics*, 26:252-63
- Karayiannis, N.B., Venetsanopoulos, A.N. (1993) *Artificial neural networks: Learning algorithms, Performance evaluation and applications*, Kluwer Academic Publishers, Boston, USA
- Kohzadi, N., Boyd, M. S., Kaastra, I., Kermanshahi, B. and Scuse , D. (1995) Neural networks for forecasting: An introduction, *Canadian Journal of Agricultural Economics*, 43:463-474
- Krejcie, R.V., Morgan, D. W. (1970) Determining sample size for research, *Activities Educational and psychological measurement*, 30:607-610
- Kuan, C. M. and White, H. (1994) Artificial neural networks: An econometric perspective, *Econometric Reviews*, 13: 1-91
- Kumar, M., Raghuwanshi, N. S., Singh, R. , Wallender, W. W. and Pruitt , W. O. (2002) Estimating evapotranspiration using artificial neural networks: *Journal of Irrigation and Drainage Engineering*, ASCE, 128, 4: 224-233
- Le Cun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. and Jackel, L. D. (1990) Handwritten digit recognition with backpropagation network: *Advances in neural information processing system*, 2:248-257
- Leung, M. T., Engeler, W. E. and Frank, P. (1990) Fingerprint processing using backpropagation neural networks: *Processing of the international joint conference on neural networks*, 1:15-20
- Levenberg, K. (1944) A method for the solution of certain problems in least squares, *Quart. Appl. Math*, 2:164-168.
- McCullagh, P. and Nelder, J. A. (1989) *Generalized linear models*. 2 Ed. , Chapman and Hall, New York, USA
- Moshiri, S. (1998) *Neural networks vs. econometric models in forecasting inflation: Work paper of department of economics, University of Manitoba*
- Moshiri, S., Cameron, N. and Scuse, D. (1999) Static, dynamic and hybrid neural networks in forecasting inflation: *Computational economic*, 14: 219-235
- Poulton, M. M. (2001) *Computational neural networks for geophysical data processing* ,Oxford:Pergamon, 335
- Portugal, N. S. (1995) *Neural networks versus time series methods: A forecasting exercises*, 14th International Symposium on Forecasting, Sweden.
- Sejnowski, T. J., Yuhas, B. P. , Goldstein, M. H. and Jenkins, R. E. (1990) Combining visual and acoustic speech signal with a neural network improves intelligibility: *Advanced in neural information processing system*, 2:232-239
- Shchmurove, Y. (2004) *Application artificial neural networks to business: Economics and finance*, Work paper of department of economics, The university of Pennsylvania
- SubbaRao, P.V., Sikdar P.K., Krishna Rao K.V., Dhiringra S.L. (1998) Another insight into artificial neural networks through behavioural analysis of access mode choice: *Computational environmental and urban systems*, 22:485-496
- Tkacs G. (2001) Neural networks in forecasting Of Canadian GDP growth: *International Journal of Forecasting*, 17:57-69

- Turhan, M. (1995) Neural networks and computation of neural network weights and biases generalized delta rule and backpropagation of error, 1-11
- Weiss, M. S. and Kulikowski, C. A. (1991) Computer systems that learn: Classification and prediction methods from statistics, Neural nets, Machine learning and expert systems (machine learning series), Morgan Kaufmann Publishers Inc.
- White, H. (1989) Learning in artificial neural networks: A statistical perspective, neural computation, 1:425-464
- White H. (1988) Economic using neural networks: The case of IBM daily stock returns, Preceding of the IEEE international conference on neural networks, 451-458

Modeling consumer's behavior for vegetable crops in the Mayadin management organization of Tehran by using artificial Neural Network

Arya Hooshmandan¹, Vali Borimnejad²

Abstract

Demand elasticities are considerable interest for policy purposes. Farmers, food processors and retailers need to model and forecast demand to plan their production and sales, and demand elasticities are of crucial importance. The lack of study among the economic literature models for estimating demand and elasticity by artificial neural networks is the most important motivation of this study. In this paper, parameters are estimated by ANN in MATLAB 2011a instead of traditional econometrics methods and utilizing cross section data. It is important to point out that among the input variables, some socio-demographic variables are Included , It seems that together with the traditional economic variables (price and income) also some non-economic factors, can affect the consumers' choices. Unlike the more traditional demand systems models that are parametric, the neural network approach is non-parametric and therefore more flexible since it is capable to capture complex non-linear interactions between input and output variables in a system. In this paper the consumer's behaviour in the Mayadin management organization of Tehran for vegetable crops "summer crops like potato, onion, tomato and so on" market is modeled using the Artificial Neural Network, in particular the demand curve and the elasticities are estimated.

Jel: C14, C45, Q11

Keywords: Modeling, Artificial Neural Network, Demand, Elasticity

¹ M. S. Agricultural Economics Student, Agricultural economics section of Islamic Azad University, Karaj Branch

² associate professor of Agricultural economics section of Islamic Azad University, Karaj Branch
Arya773@yahoo.com