

مدل شبکه عصبی در برآورد تقاضای دورکاری: روشی برای کاهش ترافیک شهری

امیررضا ممدوحی^{۱*}، آنام اردشیری^۲

۱- استادیار گروه برنامه‌ریزی حمل‌ونقل، دانشگاه تربیت مدرس، تهران

۲- دانشجوی دکتری مهندسی و برنامه‌ریزی حمل‌ونقل، دانشگاه ایالتی مرگان، بالتیمور

armamdoohi@modares.ac.ir

تاریخ پذیرش: ۱۳۹۰/۱۲/۲۰

تاریخ دریافت: ۱۳۹۰/۰۱/۲۸

چکیده - هزینه‌های بسیار زیاد حمل‌ونقل، محققین را به سمت استفاده از شیوه‌های کارآتر مانند دورکاری برای کاهش این هزینه‌ها سوق داده است. این شیوه نوین مدیریت حمل‌ونقل باعث کاهش حجم سفرهای کاری و هزینه‌های آن مانند مصرف سوخت، زمان سفر، آلودگی هوا و سرمایه‌گذاری در توسعه زیرساخت‌ها می‌شود. با توجه به آثار مثبت و وسیع این شیوه و پیچیدگی فرایند تصمیم‌گیری انسان، این مقاله با به‌کارگیری توان زیاد مدل‌های شبکه‌ی عصبی مصنوعی در بازسازی روابط پیچیده و غیرخطی، به مدل‌سازی تقاضای دورکاری برای نمونه شهر تهران می‌پردازد. در این مقاله از مدل پرسپترون چندلایه از نوع پس‌انتشار خطا برای برآورد دورکاری استفاده می‌شود. شبکه‌ی پیشنهادشده، ۲۱ نرون در ۳ لایه با توابع انتقال تانژانت سیگموئید، لگاریتم سیگموئید و خطی دارد. با استفاده از اطلاعات به‌دست‌آمده از پرسش‌گری طراحی‌شده، مدل‌های مختلفی با حجم نمونه‌ی ۶۷۶ پرداخت شدند. نتایج مدل پیشنهادی که با ۱۷۱ مجهول و پس از ۱۸۰۰ تکرار به هم‌گرایی رسید، گویای قابلیت بالا در بازسازی مشاهدات است، به گونه‌ای که میانگین مربعات خطا، ضریب تعیین و شاخص برآوردهای صحیح برای مجموعه‌ی آزمایش، به ترتیب، ۱/۱۷۷۰، ۰/۱۹ و ۳۹ درصد است. با استفاده از مدل پیشنهادی این پژوهش و اطلاعات چهار متغیر مستقل، می‌توان برآوردی از تعداد روز دورکاری در هفته داشت که هم‌فزونی آن‌ها برآوردی از تقاضای کلان دورکاری در سطح شهر برای تصمیم‌گیری بهتر در مورد تدوین برنامه‌های مربوط به دست خواهد داد.

واژگان کلیدی - شبکه‌های عصبی، دورکاری، ترافیک شهری

۱ - مقدمه

سرمایه‌گذاری در توسعه زیرساخت‌ها دارد. برنامه‌ریزان حمل‌ونقل معتقدند که برای کاهش این پیامدها، افزایش عرضه حمل‌ونقل به تنهایی پاسخ‌گو نیست و نیاز به روش‌هایی نوین برای مدیریت و کاهش تقاضای حمل‌ونقل است. دورکاری^۱ یکی از روش‌های مطرح برای کاهش

امروزه با رشد روزافزون جمعیت و تعداد وسایل نقلیه، حمل‌ونقل و ترافیک از مسائل و مشکلات اصلی پایتخت به شمار می‌رود که پیامدهای منفی متعددی مانند افزایش هزینه‌های مصرف سوخت، زمان سفر، آلودگی هوا و

1- Teleworking / Telecommuting

مدل‌سازی تقاضای دورکاری در بخش بعد، شبکه‌های عصبی و داده‌های گردآوری شده از طریق پرسش‌گری برای این پژوهش معرفی می‌شود. سپس فرایند ساخت و پرداخت مدل و نتایج به دست آمده ارائه می‌شوند و در انتها نتیجه‌گیری و پیشنهادها بیان می‌شوند.

۲- پیشینه مدل‌سازی تقاضای دورکاری

تقاضا در حمل‌ونقل، یک تقاضای مشتق شده است که در این مفهوم، تقاضای سفر به علت نیاز به شرکت در سایر فعالیت‌ها شکل می‌گیرد. به این دلیل، در برنامه‌ریزی و مدل‌سازی آن، اطلاعات اقتصادی و اجتماعی، اصلی‌ترین ورودی‌ها است. با توجه به مشتق بودن تقاضای حمل‌ونقل، در صورت ایجاد گزینه‌ای دیگر برای رفع نیاز به شرکت در فعالیت مربوط، می‌توان تقاضا را کاهش داده یا حذف کرد. دورکاری یکی از این گزینه‌هاست که بر انجام فعالیت‌های شغلی در خانه یا محلی نزدیک خانه تمرکز دارد و باعث حذف یا کاهش طول سفرهای کاری می‌شود.

برناردینو و بن‌آکیوا (Bernardino & Ben-Akiva 1996) چارچوبی را برای فرایند به‌کارگیری دورکاری پیشنهاد دادند که بتوان از آن به عنوان ابزار پیش‌بینی تقاضای دورکاری استفاده کرد. چارچوب ارائه شده یک فرایند سه مرحله‌ای مدل‌سازی شامل تصمیمات کارفرما و کارمند بود که در این مراحل از مدل لوجیت استفاده شد.

سولویان و همکاران (Sullivan et al. 1994) برای مدل‌سازی میزان مشارکت کارمندان در دورکاری، از داده‌های رجحان بیان شده سه شهر مختلف آمریکا استفاده کردند. مدل پیشنهادشده‌ی این پژوهش‌گران از نوع لوجیت چندگانه و روش پرداخت بیشینه درست‌نمایی بود. مدل نهایی با ۶۶۲ نمونه میزان برآزش خوبی $[R^2 = 0.147]$ داشت. نتایج این تحلیل اکتشافی نشان داد که اطلاعات

تقاضای سفر است که برای نخستین بار حدود ۳۰ سال پیش در آمریکا مطرح شد (Niles et al. 1976). آثار و تبعات مثبت این شیوه‌ی کاهش تقاضای سفر، طیف گسترده‌ای را شامل می‌شود که پژوهش در مورد آن را ضروری می‌سازد. دورکاری مفهوماً نسبتاً جدیدی در شیوه‌ی انجام کار و فعالیت‌های شغلی است که قید حضور در محل کار معمول و سنتی را در برخی از روزهای هفته حذف می‌کند. در روزهای دورکاری، کارمندان در خانه یا در نزدیکی خانه در یک مجتمع اداری (که از طریق تجهیزات مخابراتی و ارتباطی پیشرفته می‌تواند به منابع محاسباتی و داده‌ای محل اصلی کار دسترسی داشته باشد) به انجام فعالیت‌های شغلی می‌پردازند (USDOT, 1993). این نوع فعالیت با انتقال کار به سمت کارمند، به جای حرکت کارمند به سوی محل کار، تعریف می‌شود. به عبارت دیگر، جریان وسایل نقلیه (کارمندان) در شبکه‌ی خیابانی با جریان اطلاعات در شبکه‌ی مخابرات جایگزین می‌شود.

دورکاری در عرصه‌های گوناگون اقتصادی، اجتماعی، فرهنگی و زیست‌محیطی آثار مثبتی دارد که میزان این آثار تابعی از تقاضای این شیوه‌ی کاری است. برای نمونه، میزان صرفه‌جویی در مصرف سوخت، رابطه‌ی مستقیم با تقاضای دورکاری یعنی تعداد افراد دورکار^۱ یا روزهای دورکاری دارد. در ادبیات دورکاری، تقاضای دورکاری عموماً برحسب تعداد روز دورکاری در هفته برای کارمندان بیان می‌شود (Bernardino & Ben-Akiva 1996, Mahmassani et al. 2006, Mamdoohi et al. 1994).

در این مقاله، با توجه به توان زیاد مدل‌های شبکه‌ی عصبی مصنوعی در بازسازی روابط پیچیده و غیرخطی، از آن‌ها برای مدل‌سازی تقاضای دورکاری و پیش‌بینی میزان مناسب دورکاری استفاده می‌شود. پس از بررسی پیشینه‌ی

1- Teleworker / Telecommuter

رجحان بیان شده می‌تواند برای مدل‌سازی تصمیم دورکاری مناسب و مفید باشد.

مهمسانی و همکاران (Mahmassani et al. 1994) نظرات کارمندان در قالب رجحان بیان شده در ارتباط با دورکاری بر اساس خصوصیات فردی و شغلی را بررسی کردند. نتایج این پژوهش نشان داد که برنامه‌های موفق دورکاری، نیاز به تجدید نظر در طراحی مشاغل و روشی عادلانه برای ارزیابی کارکرد کارمندان دارد. همچنین، موفقیت برنامه‌ی دورکاری به مسائل مادی مرتبط با دورکاری وابسته است.

مختاریان و سالمون (Mokhtarian & Salomon 1996) به دنبال شناسایی عوامل بازدارنده و تسهیل‌کننده‌ی دورکاری براساس نمونه‌ی آماری ۶۲۸ نفری از کارمندان بودند. از این رو، از مدل لوجیت دوگانه برای شناسایی تمایل به دورکاری از منزل استفاده کردند که برآزش خوبی داشت ($\rho^2 = 0/68$). نتایج نشان داد که متغیرهای اقتصادی- اجتماعی به تنهایی در میزان برآورد دورکاری کافی نبوده و متغیرهایی همچون تنش و فشار کاری، مزیت‌های شخصی و زمان سفر نیز اهمیت دارد.

نخستین پژوهش در کشور درباره‌ی میزان به‌کارگیری دورکاری، با هدف برآورد امکان‌پذیری و مناسب بودن این شیوه‌ی کاری با توجه به خصوصیات و ویژگی‌های شغلی کارمندان انجام شد (ممدوحی، ۱۳۸۴). وجه تمایز این پژوهش، پیشنهاد رویکرد شغل/انتزاعی^۱ برای بهبود و تکمیل روند مدل‌سازی و نتایج آن است. این پژوهش، با هدف برنامه‌ریزی مرکزی با دیدگاه سامانه‌ای برای کل جامعه، به امکان‌پذیری دورکاری با به‌کارگیری انواع مدل‌های انتخاب گسسته پرداخت. نتایج این پژوهش گویای تناسب بیشتر مدل‌های لوجیت چندگانه نسبت به ساختار لوجیت

آشیاانه‌ای برای مسئله‌ی این پژوهش بود.

۲-۱- کاربرد مدل‌های هوشمند در تحلیل تقاضای حمل‌ونقل

مطالعات در زمینه به‌کارگیری دورکاری با استفاده از مدل‌های اقتصادسنجی از نوع رندگرای خطی یا مدل‌های انتخاب گسسته^۲ انجام شده است. در بسیاری از مطالعات و تحقیقات جدید در زمینه برآورد شاخص‌های حمل‌ونقل، برتری نسبی مدل‌های هوشمند (مانند شبکه‌های عصبی مصنوعی^۳، نظریه‌ی مجموعه‌های فازی^۴ و الگوریتم ژنتیک^۵) بر مدل‌های رایج و سنتی (همچون مدل‌های رندگرای خطی و انتخاب گسسته) از نظر خوبی برآزش و توان پیش‌گویی تأیید شده است.

هنشر و تون (Hensher & Ton, 2000) در یک مطالعه‌ی تطبیقی از توانایی‌های شبکه‌های عصبی و مدل انتخاب گسسته از نوع لوجیت آشیاانه‌ای^۶، مسئله انتخاب وسیله‌ی نقلیه را با استفاده از این ابزارها برای شهرهای ملبورن و سیدنی در استرالیا تحلیل کردند. نتیجه‌گیری آن‌ها بر اساس چند شاخص کیفی برای قیاس قدرت تعمیم نتایج مدل‌ها، برتری نسبی مدل شبکه‌ی عصبی را به مدل لوجیت آشیاانه‌ای تأیید می‌کند.

رجیانی و همکاران (Reggiani et al. 1998) پیرامون جابه‌جایی درون منطقه‌ای کالا در اروپا، کارکرد دو مدل انتخاب گسسته (از نوع لوجیت دوگانه^۷) و شبکه‌ی عصبی برای تحلیل مسئله‌ی انتخاب وسیله (بین جاده و ریل) را مقایسه کردند. شبکه‌ی پیشنهادی این پژوهشگران، یک شبکه‌ی عصبی دولایه پیشخور شامل چهار ورودی (مانند


2- Discrete Choice Models
3- Artificial Neural Networks
4- Fuzzy Set Theory
5- Genetic Algorithm
6- Nested Logit Model
7- Binary Logit Model

1- Abstract Job

شبکه‌ی عصبی نسبت به سایر روش‌های مرسوم در بازسازی روابط پیچیده و غیرخطی، از این ابزار برای مدل‌سازی تقاضای دورکاری و پیش‌بینی میزان مناسب دورکاری استفاده می‌شود.

۳- معرفی شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، متشکل از عناصر ساده و الهام‌گرفته از سامانه‌های عصبی موجودات زنده (نرون^۴) است که به طور موازی عمل می‌کنند. یک نرون به تنهایی برای مدل‌سازی سامانه‌های واقعی و پیچیده خیلی سودمند نیست، در حالی که چند نرون در ترکیب با هم در یک یا چند لایه، قدرت زیادی دارند. لایه‌ای که خروجی شبکه را تولید می‌کند، لایه خروجی^۵ و بقیه لایه‌ها، لایه‌های میانی یا پنهان^۶ نامیده می‌شوند (Hegan et al. 1996). معماری شبکه شامل تعداد لایه‌ها، تعداد نرون‌ها، تابع انتقال هر لایه و نحوه‌ی اتصال لایه‌ها است که بستگی به نوع مسئله دارد. تعداد متغیرهای مستقل مسئله، تعداد ورودی‌های شبکه و تعداد متغیرهای وابسته، تعداد نرون‌های لایه‌ی خروجی را تعیین می‌کنند. مقدار خروجی نرون (a) تابعی از مقدار ورودی نرون و تابع انتقال استفاده شده است (شکل ۱).



شکل (۱) مدل یک نرون ساده با تابع انتقال خطی

توابع انتقال غیرخطی، شبکه را قادر به حفظ روابط غیرخطی

زمان و هزینه) و یک خروجی (احتمال انتخاب یک شیوه‌ی حمل‌ونقل) با ۸ نرون میانی بود. قیاس توان پیشگویی این دو روش نشان داد که نتایج مدل شبکه‌ی عصبی مقدراری رضایت‌بخش‌تر است.

کلوزینسکی و الدیک (Klodzinski & Al-Deek 2003)

انتقال‌پذیری^۱ مدل تقاضای حمل‌ونقل چندوسیله‌ای^۲ کالا در بنادر بزرگ فلوریدا را بررسی کردند. آن‌ها از مدل شبکه‌ی عصبی با ساختار پس‌انتشار خطا^۳ برای شبیه‌سازی حمل‌ونقل کالا با وسایل نقلیه‌ی سنگین استفاده کردند. نتایج این مدل برای آزمون قدرت انتقال‌پذیری مدل شبکه عصبی به کار گرفته شد. به عقیده‌ی این پژوهش‌گران، با توجه به مشکلات شناسایی متغیرهای مستقل و هم‌بستگی کمتر بین آن‌ها و متغیر وابسته (حجم کامیون)، مدل‌های شبکه‌ی عصبی به دلیل توانایی ارائه‌ی مسائل پیچیده ابزار دقیق‌تر و یادگیرنده‌تری در مدل‌سازی است.

مدل‌های هوشمند، اگرچه به دنبال شناسایی رابطه‌ی علی بین متغیرهای مستقل و وابسته نیست ولی سعی در یادگیری و بازسازی ارتباط بین ورودی‌ها و خروجی‌ها به کمک روابط و الگوریتم‌های پیچیده ریاضی دارند. به بیانی دیگر، شبکه‌های عصبی پژوهش‌گران را قادر می‌سازد که مجموعه‌های پیچیده‌ای از ادراک انسان را با بهره‌گیری از ساختارهای مصنوعی نرون‌های بدن انسان تقلید کنند. توانایی ویژه‌ی شبکه‌های عصبی در تشخیص الگو و تصحیح خطا و در برآزش داده‌ها و بازسازی مشاهدات جدید، افزون بر تمایز این روش از مدل‌های سنتی تقاضا (مانند بیشینه‌سازی مطلوبیت در مدل‌های انتخاب)، آن را به یکی از ابزارهای مناسب و کارا تبدیل کرده است.

در این پژوهش، با توجه به توان برآوردی بالا مدل‌های

4- Neuron
5-Output Layer
6-Hidden Layers

1- Transferability
2- Multimodal Transportation
3- Error BackPropagation

شبکه‌های چندلایه معمولاً از توابع انتقال لگاریتم سیگموید^۴ و تانژانت سیگموید^۵ استفاده می‌کنند که دامنه‌ای نامحدود، اما بُردی محدود به ترتیب در بازه‌های [۰، ۱] و [۱، ۰] دارند. شبکه‌های پیش‌رو معمولاً یک یا چند لایه‌ی پنهان متشکل از نرون‌های سیگموید دارند. لایه‌های چندگانه از نرون‌ها با توابع انتقال غیرخطی، این اجازه را به شبکه می‌دهد که روابط خطی یا غیرخطی بین ورودی و خروجی را به خوبی یاد بگیرد. لایه خروجی خطی نیز این اجازه را به شبکه می‌دهد که هر مقداری (حتی خارج از محدوده -۱ تا +۱) را تولید کند.

به طور کلی، داده‌های مورد استفاده در مدل شبکه عصبی به دو زیرمجموعه آموزش و آزمایش تقسیم می‌شوند. مجموعه‌ی آموزش بزرگ‌تر است (معمولاً شامل ۷۰ تا ۸۰ درصد کل داده‌ها) و الگوهای یادگیری را به شبکه می‌آموزد. مجموعه‌ی آزمایش در فرایند یادگیری شبکه استفاده نمی‌شود و برای مقایسه‌ی مدل‌های مختلف از نظر قدرت شبکه در خوبی برازش به‌کار می‌رود (Hegan et al. 1996).

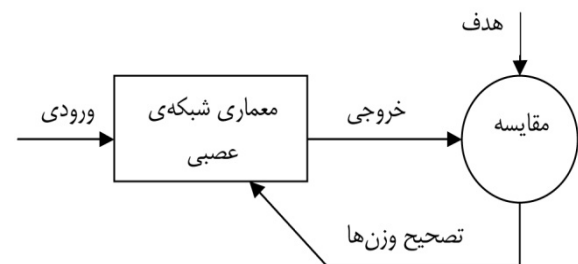
برای تعمیم شبکه‌های عصبی، دو روش به نام‌های تنظیم بایاسی^۶ و توقف زود هنگام^۷ به کار می‌روند. تابع کارکرد^۸ متداول برای شبکه‌های عصبی پیش‌رو تنها به عامل خطا وابسته است که هدف آن، کمینه کردن میانگین مربعات خطا^۹ مطابق رابطه (۱) است.

$$MSE = \frac{1}{Q} \sum_{k=1}^Q e(k)^2 = \frac{1}{Q} \sum_{k=1}^Q (t(k) - a(k))^2 \quad (1)$$

MSE تابع میانگین مربعات خطا، Q تعداد مشاهدات (مجموعه‌ی آموزش)، t مقدار متغیر وابسته (مشاهده) و

بین ورودی و خروجی می‌کند. در صورتی که اندازه‌ی بردار ورودی بزرگ باشد، با اضافه کردن لایه‌های پنهان می‌توان قدرت شبکه را در بازسازی مشاهدات افزایش داد. شبکه‌های با مقدار ثابت بایاس^۱، روابط بین ورودی و خروجی را کاراتر کاراتر از شبکه‌های بدون بایاس ارائه می‌کنند.

در این پژوهش، از ساختار پرسپترون چندلایه^۲ (MLP) از نوع پس‌انتشار خطا برای برآورد تابع انتقال غیرخطی استفاده می‌شود. شبکه‌های پس‌انتشار دارای بایاس که یک لایه میانی غیرخطی و یک لایه خروجی خطی دارند، با دیدن آموزش مناسب، توانایی تخمین هر تابعی با تعداد محدودی نقاط ناپیوستگی را دارند. یک شبکه‌ی عصبی را می‌توان برای انجام عملیات و محاسبات خاص با تصحیح مقادیر اتصالات (وزن‌های) بین عناصرش با به‌کارگیری روابط پیچیده ریاضی، چنان آموزش داد که ورودی خاصی را بر خروجی خاصی (هدف) منطبق کند (شکل ۲). برای آموزش شبکه، تعداد زیادی زوج ورودی-خروجی و روش‌های بهینه‌سازی عددی مانند الگوریتم کاهش شیب، استفاده می‌شود. در جریان آموزش شبکه، وزن‌ها و بایاس‌ها به گونه‌ای تکراری با هدف کمینه‌سازی تابع کارکرد شبکه تصحیح می‌شوند. الگوریتم‌های مختلفی برای آموزش شبکه‌های پیش‌رو^۳ وجود دارد که همگی از روش شیب برای تصحیح وزن‌ها در تابع کارکرد استفاده می‌کنند (Hegan et al. 1996).



شکل (۲) نحوه‌ی عملکرد شبکه‌های عصبی

4-Log-Sigmoid
5-Tan-Sigmoid
6-Biasian Regularization
7-Early Stopping
8-Performance Function
9-Mean Square Error

1-Bias
2-Multi Layer Perceptron
3-FeedForward Networks

مشخص کننده‌ی تعداد کل پارامترهای شبکه است که درجه‌ی آزادی مدل و یا تعداد مجهولات مسئله را نشان می‌دهند. معیاری دیگر، تعداد پارامترهای مؤثر^۳ شبکه است که بیان‌کننده‌ی تعداد پارامترهای معنی‌دار شبکه (پس از آموزش کامل) است که مقدار بیشتر آن نشان‌دهنده کارکرد بهتر شبکه است.

۴- فرآیند گردآوری داده‌ها از طریق پرسش‌گری

از آن‌جا که در ایران، هنوز کارمند دورکار رسمی وجود ندارد، امکان تهیه داده‌های رجحان نشان‌داده‌شده^۴ از دورکاری ممکن نیست. از این‌رو، آمار از نوع رجحان بیان‌شده^۵ است؛ یعنی از کسانی که دورکاری نکرده‌اند، پس از توجیه آن‌ها در مورد دورکاری و ویژگی‌های آن، نظرخواهی می‌شود. پس در این پژوهش برای مدل‌سازی تقاضای دورکاری، پرسش‌نامه‌ای طراحی شد که هدف از طراحی آن، گردآوری اطلاعات تعداد روز دورکاری مناسب در هفته (به عنوان متغیر وابسته) همراه مجموعه‌ای از متغیرهای توضیحی (به عنوان متغیرهای مستقل) بود. با توجه به مطالعات پیشین، متغیرهای مستقل در دسترس و قابل گردآوری شامل پست سازمانی، واحد سازمانی، رشته سازمانی و (گروه) وزارتخانه‌های مختلف است (ممدوحی و همکاران ۱۳۸۶).

از آنجا که گردآوری داده‌ها مستلزم هزینه‌ی زیادی است، معمولاً سعی می‌شود که فرایند گردآوری داده‌ها از نظر اقتصادی ممکن باشد (سرمد و همکاران ۱۳۸۰). با افزایش حجم جامعه، حجم نمونه با نرخی کاهشدهنده، افزایش می‌یابد و (در مطالعات اجتماعی) به عددی ثابت (حدود ۳۸۴ برای سطح اطمینان ۹۵ درصد) مجانب می‌شود

a برآورد آن به‌وسیله‌ی مدل است. روش تنظیم بایاسی شامل اصلاح تابع کارکرد شبکه است به گونه‌ای که تابع کارکرد آن، ترکیبی از همان تابع میانگین مربعات خطا و تابع میانگین مربعات وزن‌ها باشد. استفاده از این تابع کارکرد به کاهش مقدار وزن‌ها و بایاس‌ها منجر می‌شود. یک ویژگی این الگوریتم این است که معیاری برای تعداد پارامترهای معنی‌دار وزن‌ها و بایاس‌ها در شبکه می‌دهد که از آن با عنوان تعداد پارامترهای مؤثر شبکه یاد می‌شود (منهاج، ۱۳۸۴).

۳-۱- معیارهای ارزیابی مدل‌ها

در این پژوهش، برای انتخاب مدل شبکه‌ی عصبی برتر، از سه معیار برازندگی ۱- درصد برآورد صحیح؛ ۲- ضریب تعیین^۲ و ۳- میانگین مربعات خطا، در ارزیابی هر یک از مجموعه‌های آموزش و آزمایش به صورت جداگانه استفاده می‌شود. درصد برآورد صحیح (PC) به عنوان معیاری از برازندگی مدل‌های با متغیر وابسته با مقادیر گسسته مطرح است. مقادیر بزرگ‌تر این معیار به معنی بازسازی بهتر مشاهدات است. معیار ضریب تعیین (R^2) که بین صفر و یک تغییر می‌کند، بیان‌کننده‌ی میزان خوبی برازش مدل به داده‌های مشاهده است و نشان‌دهنده‌ی میزان رابطه‌ی خطی بین مشاهدات و نتایج مدل است. شاخص میانگین مربعات خطا (اختلاف مقادیر مشاهدات و نتایج مدل) (MSE) متداول‌ترین معیار ارزیابی در الگوریتم‌های آموزش شبکه‌های عصبی است، که مقدار کمتر آن نشان‌گر کارکرد بهتر شبکه است (Hegan et al. 1996).

برای مقایسه‌ی ساختارهای گوناگون شبکه‌های عصبی می‌توان از تعداد پارامترهای مجهول شبکه استفاده کرد. تعداد لایه‌ها و نرون‌ها در یک شبکه عصبی،

3-Effective Number of Parameters

4-Revealed preference data

5-Stated preference data

1-Percent Correct

2-Coefficient of Determination

نمونه مورد استفاده شده در مدل، ۵۴۱ نمونه (۸۰ درصد) برای آموزش شبکه و ۱۳۵ نمونه (۲۰ درصد) پس از ساخت و پرداخت مدل، در مرحله آزمایش شبکه به کار رفتند. این مدل با ۱۷۱ مجهول، پس از ۱۸۰۰ تکرار به هم‌گرایی رسید و ۴۶ پارامتر آن با مقادیر معنی‌دار به گونه‌ای مؤثر در یادگیری شبکه نقش داشتند.

جدول (۲)، فراوانی مقادیر برآورد مدل را در مقابل مشاهدات (تعداد روز دورکاری در هفته) برای مجموعه‌ی داده‌های آموزش نشان می‌دهد. عناصر قطر اصلی جدول، فراوانی برآوردهای صحیح (منطبق با مشاهده) مدل را نشان می‌دهند. از ۵۴۱ ورودی مدل در بخش آموزش، ۲۱۷ مورد (مجموع عناصر روی قطر اصلی) به درستی برآورد شده است. همچنین ۴۶۵ مورد (۸۶ درصد) از کل داده‌ها (مجموع عناصر روی قطر اصلی و اقطار بالا و پایین آن) با بیشینه‌ی خطای یک روز در هفته برآورد شده است. یعنی، تنها ۷۶ مورد از مشاهدات با خطای بیش از ۱ روز در هفته بازسازی شده، که از این تعداد، ۶۳ مورد خطای ۲ روز، ۱۳ مورد خطای ۳ روز و صفر مورد خطای ۴ یا ۵ روز دارد. این ارقام با توجه به وجود ۶ گزینه انتخاب (صفر تا ۵) که خطای تا ۵ روز در هفته را امکان‌پذیر می‌سازد (ولی هیچ موردی برای ۴ یا ۵ روز وجود ندارد) مناسب است.

جدول (۳) نیز فراوانی مقادیر برآورد مدل در مقابل مشاهدات برای مجموعه داده‌های آزمایش را نشان می‌دهد. از ۱۳۵ ورودی مدل در بخش آموزش، ۵۳ مورد (۳۹/۳ درصد) به درستی برآورد شده است. همچنین ۱۱۴ مورد (۸۴/۴ درصد) از کل داده‌ها با بیشینه خطای یک روز در هفته برآورد شده است.

(Krejcie & Morgan 1970). معمولاً هزینه و انرژی لازم برای گردآوری اطلاعات در حجم گسترده‌تر، اقتصادی نیست و منافع زیادی در بر ندارد، آرلک و ستل (Alreck and Settle, 1995) نیز شواهد مشابهی درباره‌ی حجم نمونه ارائه می‌کنند. بنابراین، نتایج این پژوهش با توجه به حجم نمونه (۶۷۶)، سطح اطمینان ۹۵ درصد و بیشتر دارد.

از آن‌جا که متغیرهای مستقل در این پژوهش از نوع اسمی است، ابتدا ضروری بود که کدگذاری شوند. برای نمونه، برای رسته‌های سازمانی آموزشی و فرهنگی، کد ۱ و اداری و مالی، کد ۲ یا برای پست‌های سازمانی کارشناس مسئول، کد ۱ و کارشناس، کد ۲ اختیار شد. با انتساب کدهای مربوط به مقادیر هر یک از چهار متغیر مستقل مدل، شامل رسته‌ی سازمانی (۸ کد)، پست سازمانی (۹ کد)، واحد سازمانی (۶ کد) و گروه وزارتخانه (۶ کد)، این متغیرها برای ورود به مدل آماده شدند (حدود ۲۶۰۰ حالت برای ۴ متغیر). متغیر وابسته مدل (تعداد روزهای مناسب دورکاری در هفته) نیز مقادیری بین صفر و ۵ دارد.

۵- نتایج مدل شبکه‌ی عصبی

در فرایند ساخت و پرداخت مدل شبکه عصبی برای تقاضای دورکاری (تعداد روز مناسب در هفته) با بسته‌ی نرم‌افزاری MATLAB (Demuth & Beal 1997)، شبکه‌های بسیاری با استفاده از چهار متغیر ورودی (پست، واحد، رسته و گروه وزارتخانه) ساخته و اجرا شدند. پس از ارزیابی و مقایسه نتایج آن‌ها با استفاده از معیارهای ارزیابی، مدل شبکه‌ای با مشخصات ساختاری جدول (۱) به عنوان شبکه برتر برگزیده شد. این مدل از ۳ لایه تشکیل شده است که لایه‌های میانی اول و دوم هر یک، ۱۰ نرون سیگموئید، و لایه خروجی آن، ۱ نرون خطی دارد. از ۶۷۶

جدول (۱) مشخصات مدل نهایی شبکه‌ی عصبی

| تعداد لایه‌ها | لایه‌ی میانی اول | | لایه‌ی میانی دوم | | لایه‌ی خروجی | | تعداد داده‌ها | | تعداد تکرار | تعداد پارامترها | |
|---------------|------------------|--------------------|------------------|------------------|--------------|-------------|---------------|--------|-------------|-----------------|------|
| | تعداد نرون | تابع انتقال | تعداد نرون | تابع انتقال | تعداد نرون | تابع انتقال | آموزش | آزمایش | | کل شبکه | مؤثر |
| ۳ | ۱۰ | تانزانانت سیگموئید | ۱۰ | لگاریتم سیگموئید | ۱ | خطی | ۵۴۱ | ۱۳۵ | ۱۸۰۰ | ۱۷۱ | ۴۶ |

نتایج مدل نهایی در قالب معیارهای ارزیابی، در جدول (۴) ارائه شده است. همان‌گونه که مشاهده می‌شود، میانگین مربعات خطا برای مجموعه‌های آموزش و آزمایش، به ترتیب، $۱/۰۵۳۴$ و $۱/۱۷۷۰$ است. شایان توجه است که مقدار این معیار برای مجموعه‌ی آزمایش بیش از آموزش است. مقدار ضریب تعیین مدل نیز برای مجموعه‌های آموزش و آزمایش، به ترتیب، $۰/۲۹$ و $۰/۱۹$ است که در مقایسه با مقادیر معمول و متناظر در مدل‌های انتخاب گسسته مناسب‌تر است. مقدار شاخص برآوردهای درست نیز برای مجموعه‌های آموزش و آزمایش، به ترتیب، ۴۰ و ۳۹ درصد کل مشاهدات است. با توجه به وجود ۶ گزینه، احتمال انتخاب تصادفی گزینه‌های درست، $۱۶/۷$ درصد است.

با توجه به این شاخص‌ها، مشاهده می‌شود که توان تعمیم مدل (مجموعه‌ی آزمایش) اختلاف زیادی با توان یادگیری (مجموعه‌ی آموزش) آن ندارد. این بدین معنی است که مدل، داده‌هایی را که در یادگیری و پرداختن نقشی نداشتند، به خوبی برآورد می‌کند. در مقایسه مدل‌ها، از مشاهده توانایی هم‌زمان آن‌ها در یادگیری (نتایج بخش آموزش) و تعمیم (نتایج بخش آزمایش) استفاده می‌شود. هرگاه مدلی با توانایی بالای یادگیری، نتواند نتایج مناسبی در مواجهه با ورودی‌های جدید ارائه دهد، قدرت برآورد نخواهد داشت. در حالت دلخواه، نتایج بخش آموزش باید به خوبی نتایج بخش آموزش بوده و اختلاف زیادی بین مقادیر معیارهای دو مجموعه نباشد.

جدول (۲) فراوانی برآورد و مشاهده تعداد روز دورکاری در هفته در

مجموعه آموزش

| جمع | تعداد روز دورکاری در هفته | | | | | | برآورد مشاهده |
|-----|---------------------------|---|----|-----|-----|----|---------------|
| | ۵ | ۴ | ۳ | ۲ | ۱ | ۰ | |
| ۱۴۱ | ۰ | ۰ | ۳ | ۳۴ | ۷۵ | ۲۹ | ۰ |
| ۸۳ | ۰ | ۰ | ۱ | ۴۷ | ۳۶ | ۰ | ۱ |
| ۱۶۳ | ۰ | ۰ | ۵ | ۱۲۳ | ۳۵ | ۰ | ۲ |
| ۱۱۶ | ۰ | ۰ | ۲۹ | ۷۵ | ۱۲ | ۰ | ۳ |
| ۳۴ | ۰ | ۰ | ۱۱ | ۱۵ | ۸ | ۰ | ۴ |
| ۳ | ۰ | ۰ | ۱ | ۲ | ۰ | ۰ | ۵ |
| ۵۴۱ | ۰ | ۰ | ۵۰ | ۲۹۶ | ۱۶۶ | ۲۹ | جمع |

مجموع عناصر روی قطر اصلی (مشاهدات با بازسازی درست) = ۲۱۷ ($۴۰/۱$ درصد)

مجموع عناصر روی قطر اصلی و ۲ قطر مجاور (برآوردهای با بیشینه ۱ روز خطا) = ۴۶۵ ($۸۶/۰$ درصد)

جدول (۳) فراوانی برآورد و مشاهده تعداد روز دورکاری در هفته در

مجموعه آزمایش

| جمع | تعداد روز دورکاری در هفته | | | | | | برآورد مشاهده |
|-----|---------------------------|---|----|----|----|---|---------------|
| | ۵ | ۴ | ۳ | ۲ | ۱ | ۰ | |
| ۳۷ | ۰ | ۰ | ۲ | ۸ | ۲۲ | ۵ | ۰ |
| ۲۲ | ۰ | ۱ | ۴ | ۶ | ۱۱ | ۰ | ۱ |
| ۴۳ | ۰ | ۰ | ۳ | ۳۱ | ۹ | ۰ | ۲ |
| ۲۷ | ۰ | ۰ | ۶ | ۱۹ | ۲ | ۰ | ۳ |
| ۴ | ۰ | ۰ | ۲ | ۲ | ۰ | ۰ | ۴ |
| ۲ | ۰ | ۰ | ۰ | ۲ | ۰ | ۰ | ۵ |
| ۱۳۵ | ۰ | ۱ | ۱۷ | ۶۸ | ۴۴ | ۵ | جمع |

مجموع عناصر روی قطر اصلی (مشاهدات با بازسازی درست) = ۵۳ ($۳۹/۳$ درصد)

مجموع عناصر روی قطر اصلی و ۲ قطر مجاور (برآوردهای با بیشینه ۱ روز خطا) = ۱۱۴ ($۸۴/۴$ درصد)

مشاهده، به ترتیب، برای ۴ و ۵ روز دورکاری، مدل هیچ برآوردی برای این دو مقدار نداشته است. همچنین، با وجود ۱۴۱ مشاهده برای صفر روز دورکاری، مدل تنها ۲۹ مورد برآورد صفر داشته است. این در حالی است که از ۱۶۳ مشاهده ۲ روز دورکاری، تعداد ۲۹۶ برآورد برای آن انجام شده است.

۶- خلاصه، نتیجه‌گیری و پیشنهادها

با توجه به هزینه‌های بسیار زیاد حمل‌ونقل درون‌شهری، ضرورت پرداختن به شیوه‌های کاهش تقاضای سفر هم‌زمان با سرمایه‌گذاری برای افزایش عرضه با توجه به صرفه‌جویی‌های مرتبط دوچندان می‌شود. از این‌رو، این پژوهش به مدل‌سازی تقاضای دورکاری با استفاده از شبکه‌های عصبی مصنوعی برای نمونه شهر تهران می‌پردازد. شبکه‌های عصبی، پژوهش‌گران را قادر می‌سازد که مجموعه‌های پیچیده‌ای از تصمیمات انسان را با بهره‌گیری از ساختار نرون‌ها تقلید کنند. توانایی ویژه‌ی شبکه‌های عصبی مصنوعی در برازش داده‌ها و بازسازی مشاهدات جدید، افزون بر تمایز این روش از مدل‌های سنتی تقاضا (مانند بیشینه‌سازی مطلوبیت در مدل‌های انتخاب)، آن را به یکی از ابزارهای مناسب و کارای مدل‌سازی تبدیل کرده است. در این پژوهش، از ساختار پرسپترون چندلایه از نوع پس‌انتشار خطا برای مدل‌سازی تقاضای دورکاری (تعداد روز در هفته) استفاده می‌شود. شبکه‌ی استفاده‌شده ۳ لایه و ۲۱ نرون دارد که به ترتیب از توابع انتقال تانژانت سیگموئید، لگاریتم سیگموئید و خطی استفاده می‌کند.

برای گردآوری اطلاعات، پرسش‌نامه‌های خاصی طراحی و تدوین شد و پرسش‌گری گسترده‌ای از کارکنان دولتی در شهر تهران انجام شد. هدف از طراحی این

جدول (۴) نتایج مدل نهایی شبکه‌ی عصبی در قالب معیارهای ارزیابی

| مجموعه آزمایش | | | مجموعه‌ی آموزش | | |
|---------------|----------------|--------|----------------|----------------|--------|
| PC | R ^۲ | MSE | PC | R ^۲ | MSE |
| ٪۳۹ | ۰/۱۹ | ۱/۱۷۷۰ | ٪۴۰ | ۰/۲۹ | ۱/۰۵۳۴ |

در ادامه، به نتایج و مشاهدات مهم در فرایند مدل‌سازی تقاضای دورکاری با استفاده از شبکه‌ی عصبی اشاره می‌شود.

۱. نتایج مدل‌ها نشان داد که شبکه‌های با دو لایه میانی عملکرد بهتری نسبت به شبکه‌های با یک لایه میانی با تعداد پارامتر یکسان دارند. حتی در شبکه‌های با تعداد پارامترهای مختلف، تعداد پارامترهای مؤثر در شبکه، ثابت بوده و مستقل از ابعاد و اندازه‌ی شبکه است.

۲. در فرایند مدل‌سازی، مشاهده شد که کاهش ابعاد داده‌ها باعث تضعیف قدرت مدل می‌شود. برای نمونه، حذف متغیر رسته‌ی سازمانی، کاهش داده‌های مجموعه آموزش (در راستای افزایش داده‌های آزمایش) و یا کاهش تعداد کدها (هم‌فزونی گزینه‌های تعداد روز دورکاری در هفته) باعث تضعیف نتایج شد.

۳. نتایج این پژوهش با این اصل مهم مدل‌های شبکه عصبی که برابری تعداد حالات آموزش (تعداد ورودی‌های غیرمشابه مدل) با تعداد پارامترهای شبکه باعث بهبود کارکرد شبکه می‌شود (Hegan et al. 1996)، نه تنها تناقض نداشت، بلکه تا حدودی توجیه‌کننده‌ی کارکرد مناسب مدل این پژوهش است؛ زیرا با وجود ۶۷۶ ورودی، به دلیل تکرار بسیاری از مشاهدات در مقادیر متغیرهای ورودی، تنها ۱۴۶ حالت مختلف آموزش که لزوماً خروجی‌های یکسان تعداد روز مناسب دورکاری ندارند، وجود دارد که تقریباً هم‌مرتبه با تعداد پارامترها (۱۷۱) است.

۴. مقادیر برآورد مدل شبکه عصبی، محافظه‌کارانه بوده و پیرامون میانگین مشاهدات با پراکنش کم انجام می‌شود. با رجوع به جدول (۲)، مشخص می‌شود که با وجود ۳۴ و ۳

طور کلان انجام شود، تا نتایج آن کاربردی تر باشد. در ادامه‌ی این پژوهش با توجه به اهمیت موضوع، پیشنهاد می‌شود که از سایر مدل‌های هوشمند نیز برای مدل‌سازی تقاضای دورکاری استفاده شده و نتایج آن‌ها مقایسه شود.

۷- سپاسگزاری و قدردانی

این مقاله برگرفته از بخشی از طرح پژوهشی اثرسنجی دورکاری به عنوان یک راهبرد کاهش تقاضای سفر در سطح شهر تهران است که به کارفرمایی مؤسسه عالی آموزش و پژوهش مدیریت و برنامه‌ریزی انجام شد. در این‌جا از مدیران این مؤسسه که امکان انجام این مطالعه را فراهم ساخته و در گردآوری داده‌ها کمک شایانی کردند و هم‌چنین از مدیران و کارشناسان همه‌ی ادارات و سازمان‌هایی که در امر مصاحبه و تکمیل پرسش‌نامه همکاری بسیار خوبی داشتند، سپاسگزاری می‌شود؛ هم‌چنین، از همه‌ی همکاران این طرح پژوهشی که ما را در انجام آن یاری کردند، صمیمانه قدردانی می‌شود.

۸- مراجع

[۱] سرمدی، ز؛ بازرگان، ع؛ حجازی، الف؛ "روش‌های تحقیق در علوم رفتاری"، انتشارات آگاه، چاپ پنجم، ۱۳۸۰.

[۲] ممدوحی، الف و همکاران؛ "مقدمات، تشکیل پایگاه‌های اطلاعاتی و تحلیل‌های اولیه"، طرح پژوهشی اثرسنجی دورکاری به عنوان یک راهبرد کاهش تقاضای سفر در سطح شهر تهران، گزارش نهایی مرحله‌ی اول، مؤسسه عالی آموزش و پژوهش مدیریت و برنامه‌ریزی، ۱۳۸۶.

[۳] ممدوحی، الف؛ "نقش دورکاری در مدیریت تقاضای حمل و نقل شهری، مبانی نظری و مدل‌های کاربردی"،

پرسش‌نامه، گردآوری اطلاعات تعداد روز دورکاری مناسب در هفته (به عنوان متغیر وابسته) به تفکیک ۱- پست سازمانی؛ ۲- واحد سازمانی؛ ۳- رسته سازمانی و ۴- (گروه) وزارتخانه‌های مختلف (به عنوان متغیرهای مستقل) بود. در ساخت و پرداخت مدل شبکه‌های عصبی، بسته‌ی نرم‌افزاری MATLAB و چهار متغیر ورودی (پست، واحد، رسته و گروه وزارتخانه) به کار گرفته شد. از ۶۷۶ نمونه استفاده‌شده در مدل، ۵۴۱ نمونه (۸۰ درصد) برای آموزش شبکه و ۱۳۵ نمونه (۲۰ درصد) برای آزمایش شبکه به کار رفتند. این مدل که ۱۷۱ مجهول داشت، پس از ۱۸۰۰ تکرار به هم‌گرایی رسید و ۴۶ پارامتر آن به گونه‌ای مؤثر در یادگیری شبکه نقش داشتند.

نتایج اصلی این پژوهش نشان دادند که مدل شبکه‌ی عصبی پیشنهادشده، توانایی بالایی در بازسازی مشاهدات دارد، به گونه‌ای که میانگین مربعات خطا برای مجموعه‌های آموزش و آزمایش، به ترتیب، ۱/۰۵۳۴ و ۱/۱۷۷۰ است. مقدار این معیار برای مجموعه‌ی آزمایش بیش از آموزش است. مقدار ضریب تعیین مدل نیز برای مجموعه‌های آموزش و آزمایش، به ترتیب، ۰/۲۹ و ۰/۱۹ است که در مقایسه با مقادیر معمول و متناظر در مدل‌های انتخاب گسسته مناسب‌تر است. مقدار شاخص برآورد های صحیح نیز برای مجموعه‌های آموزش و آزمایش، به ترتیب، ۴۰ و ۳۹ درصد کل مشاهدات است.

با استفاده از مدل پیشنهادی این پژوهش و اطلاعات چهار متغیر مستقل، می‌توان برآوردی از تعداد روز دورکاری در هفته داشت که هم‌فزونی آن‌ها برآوردی از تقاضای کلان دورکاری در سطح شهر برای تصمیم‌گیری بهتر در مورد تدوین برنامه‌های مربوط به دست خواهد داد. با توجه به شدت مشکل ترافیک، پیشنهاد می‌شود که مدل‌سازی و برآورد تقاضای دورکاری در سطح یک شهر به

- [12] Mahmassani HS, Yen J, Herman R and Sullivan MA (1994), Employee Attitudes and Stated Preference toward Telecommuting, Transportation Research Record 1463, pp. 31-41.
- [13] Mamdoohi AR, Kermanshah M & Poorzahedy H (2006), Telecommuting Suitability Modeling: An Approach based on the Concept of Abstract Job, Transportation, Vol. 33, No. 4, pp. 329-346, Springer, Netherlands.
- [14] Mokhtarian P & Salomon I (1996), Modeling the Choice of Telecommuting: Identifying the Choice Set and Estimating Binary Choice Models for Technology-based Alternatives, Environment and Planning A, Vol. 28, pp. 1877-1894.
- [15] Nilles J, Carlson F, Gray P & Hanneman G (1976), The Telecommunications Transportation Trade off, New York, John Wiley.
- [16] Reggiani A, Nijkamp P & Tsang W (1998), European Freight Transport Analysis Using Neural Networks and Logit Models.
- [17] Sullivan MA, Mahmassani HS & Yen J (1994), Choice Model of Employee Participation in Telecommuting under a Cost-Neutral Scenario, Transportation Research Record 1413, pp. 42-48.
- [18] US Department of Transportation (1993), Transportation Implication of Telecommuting, Washington DC.
- پایان‌نامه دکتری، مهندسی عمران، گرایش مهندسی و برنامه‌ریزی حمل و نقل، دانشگاه صنعتی شریف، ۱۳۸۴.
- [۴] منهاج، م؛ "مبانی شبکه‌های عصبی"، انتشارات دانشگاه صنعتی امیرکبیر، چاپ سوم، ۱۳۸۴.
- [5] Alreck PL & Settle RB (1995), The Survey Research Handbook, 2nd edition, Chicago, Irwin.
- [6] Bernardino A & Ben-Akiva M (1996), Modeling the process of Adoption of Telecommuting: Comprehensive Framework, Transportation Research Record 1552, pp. 161-170.
- [7] Demuth H & Beal M (1997), Neural Networks Toolbox for Use with MATLAB, The Mathworks Inc.
- [8] Hegan M, Demuth H & Beale M (1996), Neural Network Design, PWS Publishing Company.
- [9] Hensher D & Ton T (2000), A Comparison of the Predictive Potential of Artificial Neural Networks and Nested Logit Models for Commuter Mode Choice, Transportation Research Part E, pp. 155-172.
- [10] Klodzinski J & Al-Deek H (2003), Transferability of an Intermodal Freight Transportation Forecasting Model to Major Florida Seaports, Transportation Research Board.
- [11] Krejcie RV & Morgan DW (1970), Determining Sample Size for Research Activities, Educational & Psychological Measurement, 30, pp. 607-610.

Artificial Neural Network Model for Telecommuting Demand: A Technique to Decrease Urban Traffic

A.R. Mamdoohi^{1*}, A. Ardeshiri²

1- Assistant Professor, Tarbiat Modares University

2- Master of Transportation Planning and Engineering, Sharif University of Technology

armamdoohi@modares.ac.ir

Abstract:

Heavy transport costs have lead researchers in the field towards more efficient techniques to reduce peak period congestion. One such technique is telecommuting which is planned to, in line with the most travel demand management techniques, to decrease motorized trips during commuting hours. By allowing employees to work from home or a center near home equipped with telecommunication technologies, telecommuting causes an increase in efficiency of the urban transport system and a decrease in fuel consumption costs, air pollution costs and the need to invest infrastructures. Identification of the actual demand for telecommuting is a prime to analyzing the potential consequences of telecommuting in mobility improvement, congestion reduction, and energy conservation. Considering the vast socio-economic dimensions of this technique, the present paper intends to model telecommuting demand for the metropolitan of Tehran, Iran, by employing the artificial neural network (ANN) approach. ANNs are applied as a modeling tool for the complex systems of recognition and prediction, inspired by the interconnectivity of the human nervous system. ANN simulates adaptive interaction between processing elements in parallel architecture. A multi-layer perceptron model using error back propagation is deployed to predict the suitable number of weekdays telecommuting for each employment category. Using the data from an interview-filled questionnaire, designed for this purpose, various structures of ANN models were calibrated based on 80 percent of a 676 size sample. The remaining 20 percent of the preference data was preserved to assess the prediction strength of the model as it encounters unforeseen cases. Four endogenous inputs that inferred from organizational characteristics of employees arrayed the neural network model. Due to unordered nominal values of independent variables, ANN was determined to be an appropriate approach to recognize the telecommuting suitability pattern. The proposed neural network is composed of 21 neurons in 3 layers with tan-sigmoid, log-sigmoid, and linear transfer functions in the corresponding hidden and output layers. Results of the proposed model with 171 unknown parameters, converging after 1800 iterations, indicated a fair capability to replicate observations, such that mean square error, coefficient of determination, and percent correct criteria for the test set equaled, respectively, 1.177, 0.19 and 39 percent. The ANN model successfully estimated the stated quantities of telecommuting days per week, within a range of one day error, to 86 percent and 84 percent correct for the train and test sets, respectively. The evaluation results of train and test subsets are relatively close, which indicates a low generalization error, meanwhile demonstrates the reliability of ANNs to forecast the telecommuting demand.

Keywords: neural networks, telecommuting, urban traffic