

پیش بینی سطح سازگاری نوجوانان بر اساس ویژگی های روان شناختی با استفاده از مدل های رگرسیون و شبکه های عصبی مصنوعی

حسین پورشهریار^۱

چکیده

زمینه: پژوهش حاضر یک بررسی در رابطه با ویژگی های روان شناختی نوجوانان و سطوح سازگاری آنها می باشد. با توجه به مبانی نظری در مورد روابط متقابل بین این مفاهیم از یک مدل سنتی مبتنی بر همبستگی و یک مدل نوین مبتنی بر پردازش موازی داده ها استفاده شده است. **هدف:** هدف از پژوهش حاضر بررسی توانمندی هر یک از مدل های یاد شده در پیش بینی سطوح سازگاری از طریق اندازه های مربوط به ویژگی های روان شناختی نوجوانان است. **روش:** داده های اولیه مربوط به ۱۸ ویژگی روان شناختی و ۵ سطح سازگاری از طریق اجرای آزمون های CPI و AISS بر روی ۴۵۶ دانش آموز پسر دبیرستانی شهر تهران به دست آمد. از مدل های همبستگی و تحلیل عاملی به منظور استخراج مؤلفه های اصلی، به عنوان عوامل پیش بینی کننده استفاده شد. بر این اساس یک ترکیب چهار عاملی از ویژگی های روان شناختی و پنج ویژگی مستقل به عنوان ترکیب بهینه در پیش بینی سطوح سازگاری با قابلیت معادل ترکیب اولیه هجده عاملی شناسایی شدند. همچنین با توجه به انبوه عوامل اثرگذار و پیچیدگی های موجود در روابط میان آنها از مدل شبکه های عصبی مصنوعی نیز برای پیش بینی استفاده شد و توانمندی آن با مدل رگرسیون مورد مقایسه قرار گرفت. **یافته ها:** یافته ها نشان داد که مدل شبکه های عصبی مصنوعی در پیش بینی پنج سطح سازگاری توانمندتر از مدل رگرسیون می باشد و در صورت کاهش تعداد سطوح سازگاری به سه سطح، این قابلیت به نفع مدل رگرسیون تغییر می کند ($\alpha < 0,001$). **بحث و نتیجه گیری:** بر این اساس ویژگی های منحصر به فرد شبکه های عصبی مصنوعی نظیر پردازش موازی و تشخیص الگوهای ارتباط غیرخطی و پیچیده از طریق یادگیری و تجربه و قابلیت اختصاصی مدل رگرسیون در پیش بینی بر اساس اولویت بندی نقش هر یک از عوامل پیش بینی کننده از عوامل اصلی موفقیت هر یک از آنها تلقی می شود. **واژگان کلیدی:** ویژگی های روان شناختی، سازگاری، پیش بینی، رگرسیون، شبکه های عصبی مصنوعی.

مقدمه

سال‌ها است که شبکه‌های عصبی مصنوعی (ANNs^۱) به عنوان یک ابزار توانمند و یک روش مهم وارد عرصه پژوهش در علوم تجربی و به ویژه در حوزه‌های مهندسی و صنعتی شده است. پیشینه کاربرد این روش در روان‌شناسی خیلی زیاد نیست و اندک پژوهش‌های انجام شده با بهره‌گیری از این مدل در حوزه علوم رفتاری نیز در پشت کاربردهای فراوان ANNs در صنعت، مهندسی و علوم تجربی پنهان شده بود. این در حالی است که مدل‌های تجربی به اندازه کافی تأمین‌کننده نیازهای روش‌شناختی و پژوهشی حوزه‌های یاد شده بوده و با توجه به محدودیت‌های مدل‌هایی نظیر همبستگی، شبه تجربی و نیمه تجربی، نیاز به بهره‌گیری از مدل‌هایی چون ANNs در علوم انسانی و رفتاری بیشتر محسوس است. امروزه بخشی از این تأخیر از طریق استفاده دو منظوره روان‌شناسان از ANNs جبران شده است. بر این اساس از شبکه‌های عصبی مصنوعی هم به عنوان یک ابزار آماری برای تحلیل دقیق‌تر داده‌ها (وربوس^۲، ۱۹۷۴ به عنوان یک مثال قدیمی) و هم به عنوان یک مدل برای شبیه‌سازی موضوعات مختلف و پدیده‌های متنوع روان‌شناختی نظیر شخصیت و عوامل آن (کاشانی^۳ و همکاران، ۱۹۸۷، هیدریچ^۴، ۱۹۹۳؛ هومر^۵، ۱۹۹۹؛ رید^۶ و میلر^۷، ۲۰۰۲a و ۲۰۰۲b؛ مایرسی^۸ و همکاران، ۲۰۰۷)، تغییرات هیجانی (تاگارد^۹ و نرب^{۱۰}، ۲۰۰۲؛ گوپیچ^{۱۱}، ۲۰۰۲؛ لوین^{۱۲}، ۲۰۰۷؛ مرمیلود^{۱۳} و همکاران، ۲۰۱۰) تشخیص -

1. artificial neural networks
2. Werbos, P.
3. Kashani, J.H.
4. Heydrich, G.J.
5. Homer, R.
6. Read S. J.
7. Miller, L.
8. Mairesse, F.
9. Thagard, P.
10. Nerb, J.
11. Gopych, P.M.
12. Levine, D.S.
13. Mermillod, M.

های بالینی، و طبقه‌بندی اختلالات روانی (زوو^۱ و همکاران، ۱۹۹۶؛ اسپیتزر^۲، ۱۹۹۸؛ اشتاین^۳ و لودیک^۴، ۱۹۹۸؛ پرایس^۵ و همکاران، ۲۰۰۰؛ گریپونجی^۶ و پانات^۷، ۲۰۰۴؛ گروسی^۸ و همکاران، ۲۰۰۵؛ هامر^۹ و همکاران، ۲۰۰۵؛ رویین و همکاران، ۲۰۰۷؛ لیندر^{۱۰} همکاران، ۲۰۰۸)، ناهماهنگی شناختی^{۱۱} (وان‌اوروال^{۱۲} و جردنز^{۱۳}، ۲۰۰۲)، ادراک (رید^{۱۴} و یورادا^{۱۵}، ۲۰۰۳؛ کالدارا^{۱۶} و عبدی^{۱۷}، ۲۰۰۶؛ مرملود و همکاران، ۲۰۰۹)، حافظه و آسیب‌های شناختی (بوت وینیک^{۱۸} و پلوت^{۱۹}، ۲۰۰۶؛ چاتیر^{۲۰}، ۲۰۰۷؛ نرمن، نیومن و دتر^{۲۱}، ۲۰۰۷؛ کویتانا^{۲۲}، ۲۰۱۲)، تکلم (گلدریک^{۲۳}، ۲۰۱۲) و نظایر آنرا تبیین نموده و نظریه‌های کلاسیک مانند مدل پیازه از تحول مرحله‌ای شناخت‌ها (مولنار^{۲۴} و رایجمیکرز^{۲۵}، ۲۰۰۰ و ۲۰۰۴) را بازنگری کنند.

توانمندی‌های ANNs بیشتر از آن جهت اهمیت یافته است که روش‌شناسی پژوهش

1. Zou, Y.
2. Spitzer, M.
3. Stein, D.
4. Ludik, J.
5. Price, R. K.
6. Giripunje, Sh.
7. Panat, A.
8. Grossi, E.
9. Hammer, B.
10. Linder, R.
11. cognitive dissonance
12. Van Overwalle, F. V.
13. Jordens, K.
14. Read, S.J.
15. Urada, D.I.
16. Caldara, R.
17. Abdi, H.
18. Botvinick, M.
19. Plaut, D. C.
20. Chartier, S.
21. Norman, K.A., Newman@ Detre
22. Quintana, M.
23. Goldrick, M.
24. Molenaar, P.C.M
25. Raijmakers, M. J

و تجزیه و تحلیل داده‌ها در علوم رفتاری همواره با چند مشکل و محدودیت اساسی روبرو بوده است. برخی از آنها مربوط به پیش فرض‌های لازم برای استفاده از مدل‌های پژوهشی مبتنی بر روش‌های تجربی است و برخی دیگر به ایرادهای وارد بر روش‌های آماری سنتی مرتبط است. از نقطه نظر آماری، شاخص‌هایی نظیر میانگین و انحراف معیار به عنوان دو نماینده مهم و معتبر از داده‌ها از آن جهت در بیشتر مدل‌های آماری ایفای نقش می‌کنند که مشاهده همزمان تمام داده‌ها امکان‌پذیر نمی‌باشد. اگر چه سرعت و دقت رایانه‌ها در پردازش داده‌ها به ویژه در نرم‌افزارهای نوین آماری قابل توجه است، اما اساس نظری و مبانی منطقی استفاده از روش‌های آماری با استفاده از رایانه همچنان سنتی و مبتنی بر چند شاخص محدود باقی مانده است و متناسب با نیازهای امروزه برای پردازش داده‌ها نیست. پیامد این محدودیت آن است که تعداد انبوهی از روابط غیرخطی و پیچیده بین داده‌ها در شاخص‌های یادشده مشاهده نمی‌شود. از نقطه نظر روش شناختی، پژوهشگران علوم رفتاری از روش‌هایی مانند روش‌های تجربی برای تحلیل داده‌هایی استفاده می‌کنند که آن داده‌ها عمدتاً نادقیق، ناقص، همپوش، توأم با خطا و افت هستند، و ماهیت ارتباط آنها پیچیده و غیرخطی بوده و به آسانی در معادله‌های موجود نمی‌گنجنند. این ویژگی‌ها در کنار سایر محدودیت‌ها نظیر روایی و اعتبار اندازه‌ها باعث توجه به سایر روش‌های پژوهشی نظیر روش‌های نیمه تجربی و شبه تجربی شده است. اگر چه برخی از طرح‌های پژوهشی نظیر مطالعه تغییرات گروهی به جای بررسی‌های فردی تا حدودی این نگرانی‌ها را کاهش داده است، هنوز در پایه‌های روشی که برای یکسان کردن اعضاء گروه در بسیاری از این طرح‌ها مورد استفاده قرار می‌گیرد ابهاماتی وجود دارد. امروزه مدل‌های نوین پردازش داده‌ها که عمدتاً از سیستم‌های خبره و هوشمند بهره می‌گیرند به دلیل برخی مشکلات و نواقص در مدل‌های پژوهشی رایج و سنتی، بیش از پیش مورد علاقه پژوهشگران در حوزه روان‌شناسی قرار گرفته‌اند. روش‌های تجربی می‌توانند نیازهای روش شناختی در حوزه‌های علوم تجربی را تأمین نمایند، در حالی که علمی نظیر روان‌شناسی از مشکلات و محدودیت‌های اساسی و پایه‌ای روش شناختی و آماری نظیر

برابری واریانس‌ها و نرمال بودن منحنی توزیع و سایر پیش‌فرض‌هایی که برای استفاده از روش‌های تجربی لازم است رنج می‌برند. پورشهریار و همکاران (۱۳۸۸) این محدودیت‌ها را در چهار زمینه الف) روش‌های پژوهش، ب) متغیرها، ج) شاخص‌ها و د) روش‌های اندازه‌گیری مورد بررسی قرار داده‌اند.

بسیاری از محدودیت‌های یادشده در روش‌هایی که داده‌ها را به صورت موازی پردازش و محاسبه می‌کنند دیده نمی‌شود. برای مثال توانمندی اختصاصی ANNs برای پردازش مکرر و موازی تمام داده‌های اولیه به پژوهشگر اجازه می‌دهد تا قبل از آنکه خود را به چند فرضیه از پیش تعیین شده محدود کند، بتواند تعداد زیادی از فرضیه‌های ممکن را به صورت گام به گام بیازماید. همان‌گونه که اسمیت^۱ و تلن^۲ (۲۰۰۳) مطرح کرده‌اند، مدل‌هایی مانند ANNs توانسته‌اند پویایی و تغییرپذیری مستمر در داده‌های رفتاری که به صورت سنتی یک تهدید برای پژوهشگران بوده است را به یک فرصت و شرط لازم برای مطالعه تبدیل نماید. قدر مسلم آن است که توجه به حوزه‌های بین‌رشته‌ای نظیر ANNs به معنی تلاش برای آشتی دادن میان رشته‌های مختلف از طریق یک روش میانه نیست، بلکه همان‌گونه که گاستلو^۳ (۲۰۰۱ و ۲۰۰۴) اشاره کرده است لازم است تا به طور همزمان از توانمندی‌های اختصاصی هر یک از آنها استفاده شود.

علیرغم تفاوت‌های یادشده در مورد ویژگی‌ها و توانمندی‌های اختصاصی مدل ANNs و روش‌های سنتی آماری، برخی از پژوهشگران سعی دارند تا مبانی نظری مشترکی میان آنها بیابند. ایده ارائه شده در مقاله وایت^۴ (۱۹۸۹) به عنوان یک مورد قدیمی، آن است که در روش‌های مختلف یادگیری که برای آموزش ANNs مورد استفاده قرار می‌گیرند می‌توان همان فنون آمار سنتی را مشاهده نمود. او همچنین ادامه می‌دهد که تئوری‌های آماری می‌توانند بینش قابل توجهی را در مورد محتوی، فواید و

-
1. Smith, L. B.
 2. Thelen, E.
 3. Guastello, S.J.
 4. White, H.

محدودیت‌های روش‌های مختلف یادگیری در شبکه‌ها ارائه دهند. چنگک^۱ و تیتترینگتن^۲ (۱۹۹۴) نیز یک تبیین آماری برای ANNs ارائه می‌دهند و سارلی^۳ (۱۹۹۴) اشاره می‌کند که پرسپترون چند لایه^۴ به عنوان یک شبکه عصبی پر کاربرد در واقع چیزی بیشتر از رگرسیون غیرخطی نیست. عبدی^۵ (۲۰۰۳) براین باور است که فرآیند یادگیری که از طریق سازگاری وزن‌های ارتباطی میان نرون‌ها در شبکه‌های عصبی مصنوعی بدست می‌آید در واقع معادل ارزش a و b هستند که به عنوان پارامترهای اصلی در معادله رگرسیون $(\hat{y}=a+bx)$ تخمین زده می‌شوند.

در زمینه ارتباط ویژگی‌های روان‌شناختی و سازگاری افراد به عنوان متغیرهای مورد توجه در این پژوهش نیز از ANNs استفاده شده است (نیر^۶ و دیگران، ۲۰۰۱؛ مایرسی^۷ و والکر^۸، ۲۰۰۶؛ مایرسی و دیگران، ۲۰۰۷). اندازه‌های مربوط به ویژگی‌های روان‌شناختی و سطوح سازگاری از آن جهت برای مقایسه توانمندی دو مدل شبکه‌های عصبی مصنوعی (ANNs) و رگرسیون لجستیک (LR^۹) استفاده شد که پویایی و پیچیدگی به عنوان یک ویژگی که به نظر می‌رسد بیشتر توسط مدل ANNs قابل تشخیص باشد در بسیاری از تعاریف ارائه شده برای شخصیت - نظیر تعریف آلپورت^{۱۰} (۱۹۳۷)، به نقل از آسندورف^{۱۱} و دنیس^{۱۲} (۲۰۰۶) مورد توجه ویژه قرار گرفته است. بنابراین در پژوهش حاضر سطوح سازگاری در کنار ویژگی‌های روان‌شناختی به عنوان دو متغیر اصلی برای بررسی و مقایسه توانمندی دو مدل ANNs و LR در پیش‌بینی در نظر گرفته شده‌اند.

1. Cheng, R.B.
2. Titterington, D.M.
3. Sarle, W.S.
4. multi-layer perceptron (MLP)
5. Abdi, H.
6. Nair, J.
7. Mairesse, F.
8. Walker, M.
9. Logistic regression
10. Allport, G.
11. Asendorpf, J.B.
12. Denissen, J.J.A.

پژوهش‌های زیادی در حوزه روان‌شناسی برای مقایسه توانمندی دو روش یاد شده صورت گرفته است. بخش زیادی از این پژوهش‌ها (نیر^۱ و همکاران، ۲۰۰۱؛ سومر^۲ و همکاران، ۲۰۰۴؛ سیرز^۳ و آنتونی^۴، ۲۰۰۴) از داده‌های مورد استفاده در پژوهش‌های پیشین بهره گرفته‌اند. نتایج بررسی‌های مقایسه‌ای بین توانمندی مدل شبکه‌های عصبی مصنوعی و روش‌های رگرسیونی در پیش‌بینی و کشف روابط بین داده‌ها در قلمرو روان‌شناسی نشان دهنده قابلیت ویژه مدل شبکه‌های عصبی مصنوعی است (ولاکونیکولیس^۵، ۲۰۰۰؛ سوباسی^۶ و ارسلبی^۷، ۲۰۰۵). در بیشتر این پژوهش‌ها یافته‌های هر یک از مدل‌ها با استفاده از شاخص‌هایی نظیر حساسیت^۸، ویژگی^۹، کاپا^{۱۰} و یا آزمون‌هایی نظیر مک‌نمار^{۱۱} و t تست مورد مقایسه قرار گرفته‌اند.

سؤال اساسی در پژوهش حاضر این است که در صورت تغییر سطح پیچیدگی در روابط بین متغیرها، چه تغییری در قدرت پیش‌بینی هر یک از مدل‌های رگرسیون لجستیک و شبکه‌های عصبی مصنوعی ایجاد می‌شود؟ برای پاسخ این سؤال پیچیدگی روابط بین متغیرها از طریق دستکاری و ایجاد تغییر در ترکیب و تعداد ویژگی‌های روان‌شناختی به عنوان متغیر پیش‌بینی کننده و سطوح سازگاری به عنوان متغیر پیش‌بینی شونده کم و یا زیاد شده و سپس توانایی اختصاصی هر یک از این مدل‌ها مورد ارزیابی مقایسه‌ای قرار گرفته‌اند.

۲- روش

1. Nair, J.
2. Sommer, M.
3. Sears, E.S.
4. Anthony, J.C.
5. Vlachonikolis, I.G.
6. Subasi, A.
7. Ercelebi, E.
8. sensitivity
9. specificity
10. kappa
11. mc-nemar

۲-۱- آزمودنی‌ها

چهار دبیرستان به صورت تصادفی از میان دبیرستان‌های پسرانه منطقه ۳ اداره آموزش و پرورش شهر تهران انتخاب شدند. ۴۵۶ دانش‌آموز در دسترس از میان ۲۶۵۰ دانش‌آموز مقطع سوم و چهارم دبیرستان (با محدوده سنی ۱۵/۳۳ سال تا ۱۷/۵۸ سال با میانگین ۱۶/۴۲ سال) انتخاب گردیدند. تمام آزمودنی‌ها در گروه‌های ۱۵-۲۰ نفره مورد آزمون قرار گرفتند. آزمودنی‌ها بر اساس معیار ارائه شده در راهنمای AISS در پنج گروه کاملاً سازگار (۲۰/۴٪)، سازگار خوب (۲۰/۴٪)، سازگار (۱۳/۴٪)، ناسازگار (۲۳/۵٪) و کاملاً ناسازگار (۲۲/۴٪) طبقه‌بندی شدند. داده‌های مربوط به متغیرهای پیش‌بینی کننده شامل ۱۸ نمره از ویژگی‌های روان‌شناختی بودند که میانگین و انحراف معیار آنها در جدول ۱ آمده است.

۲-۲- آزمون‌ها

سیاهه روان‌شناختی کالیفرنیا (CPI): ۱۸ ویژگی روان‌شناختی با استفاده از فرم اصلی CPI (گاف، ۱۹۷۵) اندازه‌گیری شدند. آزمون CPI یک آزمون خودگزارش‌دهی است که دارای ۴۸۰ عبارت درست-غلط می‌باشد و ۱۸ ویژگی روان‌شناختی را پوشش می‌دهد. این ویژگی‌ها عبارتند از زنانگی^۲ (Fe.)، انعطاف‌پذیری^۳ (Fx.)، اشتراک^۴ (Cm.)، مدارای اجتماعی^۵ (To.)، مسئولیت‌پذیری^۶ (Re.)، کنترل خود^۷ (Sc.)، اجتماعی شدن^۸ (So.)، سلطه‌جویی^۹ (Do.)، مردم‌آمیزی^{۱۰} (Sy.)، خود‌پذیری^{۱۱} (Sa.)، حضور اجتماعی^{۱۲}

1. Gough, H.G.
2. femininity
3. flexibility
4. communality
5. tolerance
6. responsibility
7. self-control
8. socialization
9. dominance
10. sociability
11. self-acceptance
12. social-presence

پیشرفت از طریق تبعیت جویی^۱ (Ac.)، کارآمدی عقلی^۲ (Ie.)، بهزیستی^۳ (Wb.)، ظرفیت برای منزلت اجتماعی^۴ (Cs.)، خوب‌نمایی^۵ (Gi.)، پیشرفت از طریق عدم وابستگی^۶ (Ai.) و توانمندی روان‌شناختی^۷ (Py.). تمامی مواد آزمون در ابتدا توسط دو روان‌شناس به فارسی ترجمه شدند و سپس یک مترجم آن را به انگلیسی برگرداند. بازنگری پایانی پس از اجرای آزمایشی بر روی ۳۸ دانش‌آموز صورت گرفت. آزمون CPI به جهت ماهیت و ساختار متغیر مورد پیش‌بینی (سازگاری) و همچنین به دلیل گستره وسیع و کاربرد فراوان آن برای ارزیابی رفتارهای مرتبط با ویژگی‌های روان‌شناختی و عوامل شخصیتی انتخاب گردید. با توجه به هدف پژوهش حاضر، سیاهه روان‌شناختی کالیفرنیا با ۱۸ ویژگی روان‌شناسی در مقایسه با سایر آزمون‌های موجود، امکان ارائه گستره وسیع‌تری از عوامل پیش‌بینی‌کننده (از یک تا هجده عامل) را برای ارزیابی مقایسه‌ای قابلیت هر یک از مدل‌های رگرسیون لجستیک و شبکه‌های عصبی مصنوعی در درک روابط پیچیده و غیر خطی فراهم می‌نمود. نتایج یک بررسی در مورد فرم اصلی CPI با استفاده از روش آزمون، آزمون مجدد با فاصله یک ساله در میان دانش‌آموزان پسر دبیرستانی نشان داده است که مقیاس‌های این آزمون دارای محدوده اعتبار از ۰/۳۸ برای اشتراک^۸ تا ۰/۷۵ برای کنترل خود^۹ می‌باشند (گاف، ۱۹۷۵). ۷۰ پاسخنامه (۱۵٪) به صورت تصادفی برای اندازه‌گیری ضرایب اعتبار (همسانی درونی^{۱۰}) هر یک از ویژگی‌ها انتخاب شدند. بر اساس نتایج، ضریب اعتبار کل آزمون ۰/۷۱۵ محاسبه گردید که بیشترین همسانی متعلق به ویژگی کنترل خود (۰/۸۲) و کمترین همسانی متعلق به ویژگی بهزیستی (۰/۴۸) می‌باشد.

1. achievement via conformance
2. intellectual efficiency
3. sense of well-being
4. capacity for status
5. good impression
6. achievement via independence
7. psychological-mindedness
8. communality (Cm.)
9. self-control (Sc.)
10. internal consistency

پرسشنامه سازگاری برای دانش‌آموزان (AISS)^۱:

پنج سطح سازگاری با استفاده از فرم ترجمه شده AISS (سینها^۲ و ساین^۳، ۱۹۹۳) مورد اندازه‌گیری قرار گرفتند. این پرسشنامه ۶۰ سؤالی سازگاری نوجوانان را در سه حوزه هیجانی، اجتماعی و آموزشی اندازه‌گیری می‌کند و دانش‌آموزان به آنها پاسخ بلی یا خیر می‌دهند. ضرایب اعتبار در راهنمای فرم اصلی این پرسشنامه با روش آزمون-بازآزمون به میزان ۰/۹۶، ۰/۹۰ و ۰/۹۳، به ترتیب برای سازگاری هیجانی، سازگاری اجتماعی و سازگاری آموزشی (۰/۹۳ برای کل آزمون) گزارش شده است. آزمودنی‌ها بعد از تعیین نمره کل سازگاری -مطابق با راهنمای آزمون- در پنج گروه از کاملاً سازگار تا کاملاً ناسازگار طبقه بندی شدند. با توجه به سن و شرایط تحصیلی دانش‌آموزان، چنین به نظر می‌رسد که AISS آزمون مناسبی برای ارزیابی سازگاری آنان باشد. ضریب اعتبار (همگونی درونی) کل تست برای فرم فارسی AISS ۰/۹۱ می‌باشد.

۲-۳- تحلیل داده‌ها

ابتدا داده‌های مربوط به ۳۵۰ نفر از ۴۵۰ آزمودنی (نزدیک به ۷۵٪) به صورت تصادفی برای یافتن معادله رگرسیون و آموزش شبکه عصبی مصنوعی انتخاب شدند و داده‌های مربوط به ۱۰۶ آزمودنی باقیمانده برای ارزیابی نسبت پیش‌بینی‌های درست این مدل‌ها مورد استفاده قرار گرفتند. در مرحله نخست داده‌های مربوط به ۱۸ ویژگی روان‌شناختی و پنج سطح سازگاری به مدل‌های رگرسیون لجستیک و شبکه عصبی مصنوعی ارائه گردید و نسبت پیش‌بینی درست هر یک از آنها مورد محاسبه و مقایسه قرار گرفت. در پژوهش حاضر از مدل پرسپترون چند لایه به عنوان یکی از شبکه‌های عصبی پرکاربرد در پیش‌بینی داده‌ها استفاده شده است.

از سوی دیگر و برای یافتن برخی ترکیب‌های دیگر از ویژگی‌های روان‌شناختی به عنوان عوامل پیش‌بینی‌کننده به منظور دستکاری سطح پیچیدگی عوامل پیش‌بینی‌کننده از مدل

1. adjustment inventory for school students (AISS)

2. Sinha, A.K.P.

3. Singh, R.P.

تحلیل عاملی استفاده شد و چهار عامل مرتبه دوم به همراه پنج عامل مستقل استخراج گردید. همچنین ترکیب دیگری از ویژگی‌های روان‌شناختی بر اساس ارتباط آنها با سطوح سازگاری مورد شناسایی قرار گرفت، براین اساس آن دسته از ویژگی‌هایی که دارای بیشترین ارزش ویژه^۱ و کمترین ضریب β (جدول ۱) در مقایسه با سایر ویژگی‌ها بودند ($\alpha < 0.001$) با استفاده از مدل گام به گام پسرو^۲ حذف گردیدند و در پایان هفت عامل باقی ماند (Fe., Cs., Do., Wb. Cm., Ie., Fx. و Cs.) که در جدول ۲ با عنوان هفت عامل نخست آمده است.

در ابتدا تمام عوامل و ترکیب‌های عاملی مختلف به صورت جداگانه و به عنوان پیش‌بینی‌کننده برای شناسایی معادله رگرسیون و معماری مناسب شبکه بر اساس داده‌های ۳۵۰ دانش‌آموز یاد شده مورد استفاده قرار گرفتند. سپس توانمندی معادله‌ها و شبکه‌های مختلف در پیش‌بینی بر اساس داده‌های آزمودنی‌های باقیمانده مورد ارزیابی قرار گرفتند. از آزمون مک‌نمار برای مقایسه این توانمندی استفاده شد. برای ارزیابی توانمندی ANNs ابتدا شبکه‌های متفاوت با تعداد مختلف نرون در لایه میانی طراحی شدند و هر یک از معماری‌ها ده بار مورد آموزش و آزمایش قرار گرفتند و سپس میانگین نسبت‌های پیش‌بینی درست برای مقایسه با نسبت بدست آمده از مدل رگرسیون لجستیک مورد محاسبه قرار گرفت. سه شاخص برای انتخاب مناسب‌ترین شبکه عبارت بودند از: بالاترین میانگین، پایین‌ترین انحراف معیار و کمترین تعداد نرون‌ها در لایه میانی (کوچک‌ترین معماری).

با توجه به استفاده از آزمون مک‌نمار برای ارزیابی مقایسه‌ای نسبت پیش‌بینی‌های درست توسط ترکیب‌های مختلف از عوامل پیش‌بینی‌کننده و سطوح پیش‌بینی‌شونده بین دو مدل، لازم بود تا آزمودنی‌ها در تمام ارزیابی‌ها دارای موقعیت یکسان باشند. بنابراین انتخاب تصادفی ۳۵۰ آزمودنی از بین ۴۵۶ آزمودنی فقط برای یکبار در تمامی تحلیل‌های آماری صورت گرفت.

1. p-value
2. stepwise backward

جدول ۱. شاخص‌های توصیفی و نقش هر یک از ویژگی‌های روان‌شناختی در پیش‌بینی سطوح سازگاری

نقش هر یک از ویژگی‌های روان‌شناختی در پیش‌بینی				SD	M	ویژگی‌های روان‌شناختی براساس CPI
پیش‌بینی سه سطح سازگاری		پیش‌بینی پنج سطح سازگاری				
ارزش ویژه	ضریب β	ارزش ویژه	ضریب β			
۰/۰۰۱	-۰/۱۴۶	۰/۰۰۱	-۰/۱۱۸	۱۵/۸۵	۴۶/۰۹	زنانگی (Fe.)
۰/۰۱۴	۰/۰۶۶	۰/۰۰۱	۰/۰۶۴	۱۳/۷۹	۴۷/۹۹	انعطاف‌پذیری (Fx.)
۰/۰۰۲	۰/۰۷۵	۰/۰۰۱	۰/۰۷۷	۱۴/۵۴	۳۳/۰۲	اشتراک (Cm.)
۰/۸۰۲	۰/۰۰۹	۰/۷۲۲	۰/۰۰۶	۱۲/۰۶	۴۰/۰۸	مدارای اجتماعی (To.)
۰/۰۴۷	۰/۰۵۳	۰/۱۷۵	-۰/۰۱۷	۱۲/۱۷	۴۱/۲۹	مسئولیت‌پذیری (Re.)
۰/۷۵۶	-۰/۰۱۱	۰/۲۱۰	-۰/۰۱۸	۱۲/۴۰	۴۴/۶۱	کنترل خود (Sc.)
۰/۰۰۱	۰/۰۹۱	۰/۰۰۱	۰/۰۳۸	۱۴/۰۹	۴۳/۵۹	اجتماعی شدن (So.)
۰/۰۰۴	۰/۰۷۹	۰/۰۰۱	۰/۰۴۲	۱۴/۱۹	۴۵/۳۰	سلطه‌جویی (Do.)
۰/۶۲۲	۰/۰۱۴	۰/۵۹۶	-۰/۰۰۷	۱۱/۱۵	۴۲/۲۷	مردم‌آمیزی (Sy.)
۰/۰۴۱	۰/۰۵۴	۰/۶۳۲	۰/۰۰۶	۱۳/۲۶	۴۷/۴۹	خود‌پذیری (Sa.)
۰/۷۰۷	-۰/۰۱۱	۰/۱۴۵	-۰/۰۱۹	۱۳/۰۳	۴۸/۶۱	حضور اجتماعی (Sp.)
۰/۳۵۴	-۰/۰۲۲	۰/۱۲۹	-۰/۰۱۷	۱۳/۵۰	۳۷/۷۹	پیشرفت از طریق تبعیت جویی (Ac.)
۰/۰۰۵	۰/۰۶۹	۰/۰۰۰	۰/۰۵۵	۱۴/۵۷	۳۶/۴۳	کارآمدی عقلی (Ie.)
۰/۰۱۸	۰/۰۶۸	۰/۰۰۱	۰/۰۴۳	۱۱/۷۰	۳۸/۶۵	بهبزستی (Wb.)
۰/۰۳۴	-۰/۰۴۶	۰/۰۰۶	-۰/۰۲۴	۱۳/۸۴	۴۱/۵۰	ظرفیت برای منزلت اجتماعی (Cs.)
۰/۵۷۰	۰/۰۱۱	۰/۶۴۰	۰/۰۰۴	۱۱/۳۴	۴۵/۷۷	خوب‌نمایی (Gi.)
۰/۸۳۳	۰/۰۰۴	۰/۷۵۱	۰/۰۰۲	۱۳/۹۹	۴۴/۷۳	پیشرفت از طریق عدم وابستگی (Ai.)
۰/۱۸۹	۰/۰۳۲	۰/۳۱۱	۰/۰۱۱	۱۰/۱۴	۴۱/۸۹	توانمندی روان‌شناختی (Py.)

۳- نتایج

۳-۱- پیش‌بینی بر اساس ۱۸ ویژگی روان‌شناختی

همان‌گونه که در جدول ۲ آمده است، یافته‌ها نشان می‌دهد که مدل شبکه‌های عصبی مصنوعی در پیش‌بینی پنج سطح سازگاری بر اساس ۱۸ ویژگی روان‌شناختی موفق‌تر از مدل

رگرسیون لجستیک می‌باشد (۷۶٪ در مقابل ۶۶٪، $\alpha < 0,001$). این یک نتیجه غیر منتظره نیست، اما نوع خطا در پیش‌بینی با استفاده از هر یک از مدل‌ها برای تبیین برتری ANNs مهم به نظر می‌رسد. خطاها برای پیش‌بینی پنج سطح سازگاری با استفاده از معادله رگرسیون به گونه‌ای بود که افراد در صورت شکست این مدل در پیش‌بینی، در بیشتر موارد در طبقات مجاور خود قرار گرفتند، اما در توزیع خطای پیش‌بینی با استفاده از ANNs چنین سوگیری مشاهده نشد. بنابراین چنین انتظار می‌رفت که کاهش سطوح سازگاری از پنج سطح به سه سطح (خوب، متوسط و ضعیف)، آنگونه که در برخی از مطالعات دیگر نظیر کاشانی و دیگران، ۱۹۸۷ و نیز و دیگران، ۲۰۰۱ مشاهده می‌شود با افزایش بیشتر قدرت مدل رگرسیون لجستیک در پیش‌بینی درست در مقایسه با مدل ANNs همراه باشد.

جدول ۲. نسبت پیش‌بینی‌های درست برای پنج سطح سازگاری با استفاده از مدل‌های رگرسیون و

شبکه‌های عصبی مصنوعی و نتایج آزمون مک‌نمار برای مقایسه آنها

Z (مک‌نمار)	نسبت پیش‌بینی‌های درست (بر اساس هر یک از مدل‌های مورد استفاده در پیش‌بینی)		عوامل پیش‌بینی‌کننده
	رگرسیون	شبکه‌های عصبی مصنوعی	
۳,۱۲۵*	٪۶۳	٪۵۷	عامل اول (مستخرج از روش تحلیل عاملی)
۱۰,۲۵۶*	٪۶۱	٪۲۶	عامل دوم (مستخرج از روش تحلیل عاملی)
۲,۱۳۳	٪۳۶	٪۳۵	عامل سوم (مستخرج از روش تحلیل عاملی)
۴,۳۳۳*	٪۴۲	٪۳۵	عامل چهارم (مستخرج از روش تحلیل عاملی)
۱,۹۲۵	٪۵۴	٪۵۳	پنج ویژگی مستقل (مستخرج از روش تحلیل عاملی)
۳,۵۲۲*	٪۷۱	٪۶۴	هفت عامل نخست (مستخرج از روش حذف گام به گام پسرو)
۳,۲۴۰*	٪۷۶	٪۶۶	هجده ویژگی مستقل روان‌شناختی

* $\alpha < 0,001$

نتایج پژوهش حاضر نشان داد با کاهش سطوح سازگاری از پنج سطح به سه سطح، نسبت پیش‌بینی‌های درست بر اساس ۱۸ ویژگی اصلی روان‌شناختی از ۶۶٪ به ۹۵٪ برای مدل

رگرسیون لجستیک و از ۷۶٪ به ۸۶٪ برای مدل ANNs افزایش می یابد. این تغییر در سطوح متغیر پیش بینی شونده از پنج سطح به سه سطح، برتری مدل ANNs در پیش بینی درست (۷۶٪ در مقابل ۶۶٪ در پیش بینی پنج سطح) را به نفع مدل رگرسیون (۹۵٪ در مقابل ۸۶٪ در پیش بینی سه سطح) تغییر داد (جدول ۳).

جدول ۳. نسبت پیش بینی های درست برای سه سطح سازگاری با استفاده از مدل های رگرسیون و

شبکه های عصبی مصنوعی و نتایج آزمون مک نمار برای مقایسه آنها

Z (مک نمار)	نسبت پیش بینی های درست (بر اساس هر یک از مدل های مورد استفاده در پیش بینی)		عوامل پیش بینی کننده
	رگرسیون	شبکه های عصبی مصنوعی	
۱/۸۰۰	٪۸۱	٪۷۹	عامل اول (مستخرج از روش تحلیل عاملی)
۲/۵۷۱	٪۷۱	٪۷۷	عامل دوم (مستخرج از روش تحلیل عاملی)
۴/۵۴۵*	٪۴۱	٪۷۱	عامل سوم (مستخرج از روش تحلیل عاملی)
۴/۱۷۲*	٪۵۰	٪۷۱	عامل چهارم (مستخرج از روش تحلیل عاملی)
۲/۷۷۱*	٪۶۷	٪۷۴	پنج ویژگی مستقل (مستخرج از روش تحلیل عاملی)
۰/۲۰۰	٪۹۱	٪۹۱	هفت عامل نخست (مستخرج از روش حذف گام به گام پسرو)
۵/۳۳۳*	٪۸۶	٪۹۵	هجده ویژگی مستقل روان شناختی

* $\alpha < 0,001$

۳-۲- کاهش تعداد ویژگی های روان شناختی

مدل تحلیل عاملی برای کاهش تعداد متغیرهای پیش بینی کننده مورد استفاده قرار گرفت. براین اساس چهار عامل که هر یک ۴ تا ۲ ویژگی را پوشش می دادند و نیز پنج ویژگی مستقل استخراج گردیدند. عوامل به دست آمده به صورت جداگانه به هر دو مدل برای پیش بینی پنج سطح سازگاری دانش آموزان ارائه شدند. به علاوه هفت عامل نخست که با روش حذف پسرو بدست آمده بودند نیز به هر دو مدل ارائه گردید. تمام نتایج (نسبت پیش بینی های درست پنج سطح و سه سطح سازگاری) برای عوامل و ترکیب های مختلف

پیش‌بینی‌کننده در جدول ۲ (نسبت پیش‌بینی‌های درست پنج سطح سازگاری) و جدول ۳ (نسبت پیش‌بینی‌های درست سه سطح سازگاری) آمده است.

نسبت پیش‌بینی‌های درست تمام عوامل و ترکیب‌های عاملی همچنین با استفاده از آزمون مک‌نمار مورد بررسی مقایسه‌ای قرار گرفتند ($\alpha < 0.001$). همان‌گونه که در جدول ۲ و به عنوان یک نتیجه مهم مشاهده می‌شود، علیرغم تغییر در ترکیب عوامل پیش‌بینی‌کننده و کاهش آنها از ۱۸ ویژگی به تعداد کمتر (کاهش سطح پیچیدگی عوامل پیش‌بینی‌کننده) شبکه‌های عصبی مصنوعی در ۵ مورد از ۷ مورد (۷۱٪) در پیش‌بینی پنج سطح سازگاری موفق‌تر از رگرسیون لجستیک بوده است.

۳-۳- کاهش تعداد سطوح سازگاری

از دیگر سو همان‌گونه که در جدول ۳ نشان داده شده است، سطوح سازگاری نیز از پنج سطح به سه سطح کاهش یافت و سپس بر اساس همان عوامل و ترکیب‌های عاملی مورد پیش‌بینی قرار گرفت. نتایج نشان داد که با این تغییر، قدرت پیش‌بینی مدل‌ها در ۴ مورد از ۷ مورد (۵۷٪) به نفع رگرسیون لجستیک تغییر کرد.

۴- بحث

در هر یک از مدل‌های رگرسیون و شبکه‌های عصبی مصنوعی دو روش متفاوت برای گزارش نسبت پیش‌بینی‌های درست وجود دارد. نرم‌افزار SPSS بر اساس میانی مشخص و معادله رگرسیون، یک جدول ماتریسی که نشان‌دهنده تعداد آزمودنی‌هایی که در هر طبقه قرار گرفته‌اند ارائه می‌دهد و نسبت پیش‌بینی‌های درست و نادرست از این طریق قابل استخراج است. این در حالی است که نسبت پیش‌بینی‌های درست بر اساس خروجی‌های شبکه‌های عصبی مصنوعی در نرم‌افزار MATLAB معادل نسبت شباهت داده‌های مربوط به هر یک از آزمودنی‌ها را با الگوی ارتباطی تمامی طبقاتی است که با استفاده از ANNs شناسایی شده‌اند، و متناسب با تابعی که برای لایه خروجی تعریف شده است معرفی می‌شود. براین اساس توانمندی اختصاصی ANNs در شناسایی روابط پیچیده و غیرخطی میان تعداد

زیادی از متغیرها یکی از مهمترین و رایج‌ترین دلایل برتری این مدل نسبت به مدل‌های مرسوم آماری می‌باشد. در پژوهش حاضر، دو استراتژی برای کاهش پیچیدگی روابط بین متغیرها به کار گرفته شد. بر اساس استراتژی نخست تعداد عوامل پیش‌بینی کننده از ۱۸ ویژگی روان‌شناختی با استفاده از روش تحلیل عاملی کاهش یافت. نتایج نشان داد توانمندی مدل ANNs علیرغم این کاهش همچنان بر مدل رگرسیون لجستیک برتری داشت. این در حالی است که این برتری با کاهش سطوح سازگاری از ۵ سطح به ۳ به عنوان دومین استراتژی به نفع رگرسیون لجستیک تغییر کرد.

بر اساس استراتژی نخست، اگر تعداد عوامل تا آنجا کاهش یابد که ترکیبی از حداقل عوامل با بیشترین توان پیش‌بینی شناسایی شوند، در واقع ترکیب کوچکی از ویژگی‌های روان‌شناختی که بیشترین ارتباط با سطوح سازگاری دارند مورد شناسایی قرار گرفته‌اند. به عبارت دیگر این کاهش با حفظ تعداد پیش‌بینی‌های درست همراه می‌باشد. اما بر اساس استراتژی دوم اگر چه با کاهش سطوح متغیر پیش‌بینی شونده تعداد پیش‌بینی‌های درست افزایش یافته است، اما کاهش دقت در پیش‌بینی را در پی خواهد داشت. با توجه به محدودیت پیشینه پژوهش‌های مشابه با بهره‌گیری از مدل شبکه‌های عصبی مصنوعی در حوزه روان‌شناسی در ایران امکان مقایسه نتایج پژوهش حاضر کم است.

نتایج یافته‌های این پژوهش با نتایج پژوهش‌های عباسی و همکاران (۱۳۸۹)، گرین^۱ (۱۹۹۸)، پالوکسی^۲ و وایت^۳، سوباسی^۴ و ارسلی، (۲۰۰۵) همسو می‌باشد. عباسی و همکاران (۱۳۸۹) توانمندی هر یک از مدل‌های شبکه‌های عصبی مصنوعی و رگرسیونی را در پیش‌بینی رضایتمندی زناشویی ۳۰۰ زوج بر اساس ویژگی‌های شخصیتی مقایسه کردند و محدود نبودن مدل شبکه عصبی به انطباق داده‌ها با توابع از پیش تعیین شده را به عنوان یکی از اصلی‌ترین عوامل موفقیت این مدل در مقایسه با مدل سنتی رگرسیون معرفی نمودند.

-
1. Griffin, G.R.
 2. Palocsay, W.S.
 3. White, M.M.
 4. Subasi, A.

گریفین (۱۹۹۸) از دو مدل شبکه عصبی مصنوعی و رگرسیون چند متغیره برای پیش‌بینی موفقیت در دوره آموزش خلبانی (۴۵۲ دانشجو در مرکز پژوهش پزشکی هوا و فضای فلوریدا) بر اساس نتایج آزمون‌های روانی-حرکتی، ادراکی و شناختی استفاده نمود. نتایج نشان داد به نسبت افزایش تعداد متغیرهای پیش‌بینی کننده، قابلیت مدل شبکه عصبی مصنوعی در پیش‌بینی در مقایسه با مدل رگرسیون نیز افزایش می‌یابد. توانمندی اختصاصی شبکه عصبی مصنوعی در پردازش مستقیم داده‌ها بدون توجه به شاخص‌هایی مانند میانگین و یا انحراف از معیار به عنوان عامل برتری این مدل معرفی گردیده است. پالوکسی و وایت (۲۰۰۴) برای بررسی ارتباط بین ابعاد مختلف فرهنگی مانند جمع‌گرایی/فردگرایی، پدرسالاری/مادرسالاری و نظایر آن در ادراک افراد از مفهوم عدالت در نمونه ۴۶۸ دانشجو (۲۹۶ دانشجو از ایالات متحده آمریکا و ۱۷۲ دانشجو از کره جنوبی) از مدل شبکه‌های عصبی مصنوعی با پرسپترون چند لایه (۷ نرون در لایه ورودی، ۵۰ نرون در لایه میانی و یک نرون در لایه خروجی) و رگرسیون چند متغیری استفاده کردند و در تبیین دقت بیشتر مدل شبکه‌های عصبی مصنوعی در پیش‌بینی به توانمندی اختصاصی این مدل در شناسایی روابط غیرخطی بین متغیرها استناد نموده‌اند. سوباسی و ارسلی (۲۰۰۵) توانمندی شبکه‌های عصبی مصنوعی را با مدل رگرسیون لجستیک در پیش‌بینی حملات صرعی بر اساس داده‌های مربوط به موج نگار مغزی (۵۰۰ نوار ۲۴ ساعته ضبط شده از بیماران صرعی و افراد نرمال) مورد مقایسه قرار دادند و نتیجه گرفتند که معماری مناسب یک شبکه عصبی مطلوب (۴ نرون در لایه ورودی برای امواج چهارگانه آلفا، بتا، تتا و دلتا و ۱۰ نرون در لایه میانی و یک نرون در لایه خروجی) می‌تواند دستیار مناسبی برای متخصصین در تشخیص فرایند حملات صرعی باشد.

همچنین بر اساس یافته‌های بررسی حاضر می‌توان دو تعریف مستقل از قدرت پیش‌بینی ارائه داد. یک تعریف به صحت پیش‌بینی و دیگری به دقت در پیش‌بینی مربوط می‌شود که در این پژوهش به ترتیب مدل‌های رگرسیون لجستیک و ANNs هر یک از دیگری موفق‌تر بوده‌اند.

منابع

- پورشهریار، حسین، رسول‌زاده طباطبایی، کاظم، خداپناهی، محمدکریم، کاظم نژاد، نوشیروان، خفری، ثریا (۱۳۸۸). شبکه‌های عصبی مصنوعی: مدلی برای پیش‌بینی. فصلنامه روان‌شناسان ایرانی، ۲۰، ۳۰۷-۳۲۱.
- عباسی، روح ا...، رسول‌زاده طباطبایی، کاظم، کبیر، احسان ا...، ابراهیم پور، رضا، عباسی، زهرا. (۱۳۸۹). پیش‌بینی رضایتمندی زناشویی بر مبنای ویژگی‌های شخصیتی: مقایسه مدل شبکه عصبی مصنوعی و روش رگرسیون. مجله علوم رفتاری، ۴(۳)، ۱۷۱-۱۷۵.
- Abdi, H. (2003). In Lewis-Beck M., Bryman, A. and Futing T. (Eds.), *Encyclopedia of Social Sciences Research Methods*. Thousand Oaks
- Asendorpf, J.B., & Denissen, J.J.A. (2006). Predictive validity of personality types versus personality dimensions from early childhood to adulthood: implications for the distinction between core and surface traits. *Miller-Palmer Quarterly*, 52(3), 486-513. (CA): Sage.
- Botvinick, M. & Plaut, D. C. (2006). Short-term memory for serial order: A recurrent neural network model. *Psychological Review*, 113, 201-233
- Caldara, R. & Abdi, H. (2006). Simulating the "other-race" effect with autoassociative neural networks: further evidence in favor of the face-space model. *Perception*, 35(5) 659 – 670.
- Chartier, S., Renaud, P., and Boukadoum. M. (2007). A nonlinear dynamic artificial neural network model of memory. *New Ideas in Psychology*, doi:10.1016/j.newideapsych.2007.07.005
- Cheng, R.B. and Titterton, D.M. (1994). Neural Networks: A Review from Statistical Perspective. *Statistical Science*, 9 (1), 49-54.
- Giripunje, Sh. & Panat, A. (2004). Speech Recognition for Emotions with Neural Network: A Design Approach. *Knowledge-Based Intelligent Information & Engineering Systems*, 32, 640-645.
- Goldrick, M. (2012). *Neural network models of speech production*. In M. Faust (Ed.) *Handbook of the neuropsychology of language* (vol. 1, Language processing in the brain, pp. 125-145). Wiley-Blackwell.
- Gopych, P.M. (2002). Computer Modeling of Feelings and Emotions: A Neural Network Model of the Feeling-of-Knowing. *Kharkiv University Bulletin, Series Psychology*. 550, 54-58.
- Gough, H.G. (1975). *Manual for the California Psychological Inventory*. In

rev. ed. Palo Alto, CA: Consulting Psychologists Press, Inc.

- Griffin, G.R. (1998). Predicting naval aviator flight training performance using multiple-regression and an artificial neural network. *international journal of aviation psychology*, 8, 121-135.
- Grossi, E., Massini, G., Buscema, M. and Savare, R. (2005). Two different Alzheimer diseases in men and women: Clues from advanced neural networks and artificial intelligence. *Gender Medicine*, 2(2), 106-117.
- Guastello, S.J. (2001). Nonlinear dynamics in psychology. *Discrete Dynamics in Nature and Society*, 6(1), 11-29.
- Guastello, S.J. (2004). Progress in applied nonlinear dynamics: Welcome to NDPLS. *Nonlinear Dynamics, Psychology, and Life Sciences*, 8, 1-16.
- Hammer, B., Rechten, A., Strickert, M., & Villmann, Th. (2005). *Relevance learning for mental disease classification*. In M. Verleysen, editor, Proc. Of European Symposium on Artificial Neural Networks (ESANN'2005), pages 139-144, Brussels, Belgium, 2005. d-side publications.
- Heydrich, G.J. (1993). Using Neural Networks to Model Personality Development. *Medical Hypotheses*, 41, 123-130.
- Homer, R. (1999). A neural network model of personality. International Joint Conference on Neural Networks. Proceedings IEEE, Piscataway, NJ, USA, 1, 103-108.
- Kashani, J.H., Rosenberg, T., Beck, N.C., Reid, J.C. & Battle, E.F. (1987). Characteristics of well-adjusted adolescents. *Canadian Journal of Psychiatry*, 32, 418-422.
- Levine, D.S. (2007). Neural network modeling of emotion. *Physics of Life Reviews*, 4(1), 37-63.
- Linder, R., Albers, A.E., Hess, M., Poppl, S.J. & Schonweiler, R. (2008). Artificial Neural Network-based Classification to Screen for Dysphonia Using Psychoacoustic Scaling of Acoustic Voice Features. *Journal of Voice*, 22(2), 155-63.
- Mairesse, F. & walker, M. (2006). Words Mark the Nerds: Computational models of personality recognition through language. *In Proceedings of the 28th Annual Conference of the Cognitive Science Society*, 543-548.
- Mairesse, F., Walker, M.A., Mehl, M.R. & Moore, R.K. (2007). Using linguistic cues for the automatic recognition of personality in conversation and text. *Journal of Artificial Intelligence Research*, 30, 457-500.

- Mermillod, M., Bonin, P., Mondillon, L., Alleysson, D., & Vermeulen, N. (2010). Coarse Scales are Sufficient for Efficient Categorization of Emotional Facial Expressions: Evidence from Neural Computation. *Neurocomputing*, 73, 2522-2531
- Mermillod, M., Vermeulen, N., Lundqvist, D., & Niedenthal, P.M. (2009). Neural Computation as a Tool to Differentiate Perceptual from Emotional Processes: The Case of Anger Superiority Effect. *Cognition*, 110 (3), 346-357.
- Molenaar, P.C.M. & Raijmakers, M.E.J. (2000). A causal interpretation of Piaget's theory of cognitive development: Reflections on the relationship between epigenesis and non-linear dynamics. *New Ideas in Psychology*, 18, 41-55.
- Nair, J., Nair, S.S., Kashani, J.H., Reid, J.C. & Rao, V.C. (2001). A neural network approach to identifying adolescent adjustment. *Adolescent*, 36(141), 153-162.
- Norman, K.A., Newman, E.L. & Detre, G.J. (2007). A neural network model of retrieval-induced forgetting. *Psychological Review*, 114 (4), 887-953.
- Palocsay, W.S. & White, M.M. (2004). Neural Network Modeling in Cross-Cultural Research: A Comparison with Multiple Regression. *Organizational Research Methods*, 7(4), 389-399.
- Price, R. K., Spitznagel, E. L., Downey, T. J., Meyer, D. J., Risk, N.K., & Ghazzawy, O.G. (2000). Applying Artificial Neural Network Models to Clinical Decision Making. *Psychological Assessment*, 12(1), 40-51.
- Quintana, M., Guàrdia, J., Sánchez-Benavides, G., Aguilar M., & Neuronorma Study Team (2012). Using artificial neural networks in clinical neuropsychology: high performance in mild cognitive impairment and Alzheimer's disease. *Journal of Clinical and Experimental Neuropsychology*, 34(2), 195-208.
- Raijmakers, M. E. J. & Molenaar, P.C.M. (2004). Modeling developmental transitions in adaptive resonance theory. *Developmental Science*, 7 (2), 149-157.
- Read, S.J. & Miller, L.C. (2002a). *Neural network models of personality & social behavior*. Grant submitted to NIMH.
- Read, S.J. & Miller, L.C. (2002b). Virtual Personalities: A Neural Network Model of Personality. *Personality and Social Psychology Review*, 6(4), 357-369.
- Read, S.J. & Urada, D.I. (2003). A neural network simulation of the out group homogeneity effect. *Personality and Social Psychology Review*,

7, 146–159.

- Rippon, G., Brock, J., Brown, C. & Boucher J. (2007). Disordered connectivity in the autistic brain: challenges for the new psychophysiology. *International Journal of Psychophysiology*, 63(2), 164-172.
- Sarle, W.S. (1994). Neural Networks and Statistical Models. Proceedings of the Nineteenth Annual SAS Users Group International Conference, *SAS Institute Inc., Cary, NC, USA*.
- Sinha, A.K.P., & Singh, R.P. (1993). *The Adjustment Inventory for School Students (AISS)*. Agra. National Psychological Corporation.
- Smith, L. B., & Thelen, E. (2003). Development as a dynamic system. *Trends in Cognitive Science*, 7, 343-348.
- Sommer, M., Schuhfried, G., Olbrich, A. & Arendasy, M. (2004). Improvements in Personnel Selection With Neural Networks: A Pilot Study in the Field of Aviation Psychology. *International Journal of Aviation Psychology*, 14, (1), 103-115.
- Spitzer, M. (1998). The history of neural network research in psychopathology. In D. Stein and J. Ludick (Eds.) *Neural Networks and Psychopathology*, pp. 14-33. Cambridge: Cambridge University Press.
- Stein, D. & Ludick, J. (1998). *Neural Networks and Psychopathology: Connectionist Models in Practice and Research*, Cambridge: Cambridge University Press.
- Subasi, A. & Ercelebi, E. (2005). Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, 78(2), 87-99.
- Thagard, P., & Nerb, J. (2002). Emotional gestalts: Appraisal, change, and the dynamics of affect. *Personality and Social Psychology Review*, 6 (4), 274-282.
- VanOverwalle, F. & Jordens, K. (2002). An adaptive connectionist model of cognitive dissonance. *Personality and Social Psychology Review*, 6, 204–231.
- Vlachonikolis, I.G., Karras, D.A., Hatzakis, M.J. & Paritsis, N. (2000). Improved Statistical Classification Methods in Computerized Psychiatric Diagnosis. *Medical Decision Making*, 20(1), 95 - 103.
- Werbos, P. (1974). *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. Ph.D. Dissertation, Harvard University, Committee on Applied Mathematics.

-
- White, H. (1989). Learning in Artificial Neural Networks: A Statistical Perspective. *Neural Computation*, 1 (4), 425-464.
- Zou, Y., Shen, Y., Shu, L., Wang, Y., Feng, F., Xu, K., Qu, Y., Song, Y., Zhong, Y., Wang, M. & Liu, W. (1996). Artificial neural network to assist psychiatric diagnosis. *British Journal of Psychiatry*, 169, 64-67.