

توابع چندربعدی معکوس به عنوان اثرات غیرخطی در مدل‌های رگرسیون لوزستیکی

آرزو مجیری^۱، سروش علیمرادی^۱، محمدرضا احمدزاده^۲

^۱دانشکده علوم ریاضی، دانشگاه صنعتی اصفهان

^۲دانشکده برق و علوم کامپیوتر، دانشگاه صنعتی اصفهان

تاریخ دریافت: ۱۳۹۲/۳/۷ تاریخ آخرین بازنگری: ۱۳۹۲/۶/۱۳

چکیده: یک روش آماری رایج برای دسته‌بندی، استفاده از مدل‌های رگرسیون لوزستیک است. این روش با درنظر گرفتن اثرات خطی از ویژگی‌های افراد یا اشیا به مدل‌سازی احتمالات پسین عضویت در هر دسته می‌پردازد. در عمل این گمان وجود دارد که اثرات غیرخطی ویژگی‌ها می‌توانند نقش مؤثری در دسته‌بندی صحیح مشاهدات داشته باشند. اما مسئله‌ای که در پی ورود اثرات غیرخطی به مدل لوزستیک مطرح می‌شود، برآوردهای پارامترها است. تحقیقات در سال‌های اخیر با فرض اثرات غیرخطی مانند اثرات متقابل و توابع پایه شعاعی گاوی در مدل، برای پاسخ به مسئله برآوردهای پارامترها است. در این تکاملی و روش‌های برآوردهای ماکسیمم درستینمایی را پیشنهاد کردند. در این مقاله نوعی از توابع پایه شعاعی با نام توابع چندربعدی معکوس به عنوان اثرات غیرخطی در مدل لوزستیک در نظر گرفته می‌شود و با روش ترکیبی، پارامترهای مدل برآورد می‌شوند. آزمایشات تجربی برای مقایسه مدل‌های پیشنهادی در این مقاله، با استفاده از داده‌های پژوهشی و داده‌های واقعی مربوط به یک کارخانه تولید

آدرس الکترونیک مسئول مقاله: آرزو مجیری, arezu.mojiri@math.iut.ac.ir

کد موضوع بنای ریاضی (۲۰۱۰): ۶۲۱۲

فولاد انجام گرفته است. نتایج نشان می‌دهد که حضور توابع چندرباعی معکوس نسبت به توابع گاوی در مدل، می‌تواند باعث افزایش دقت دسته‌بندی شود.

واژه‌های کلیدی : دسته‌بندی، رگرسیون لوژستیک، توابع چندرباعی معکوس، شبکه‌های عصبی تکاملی.

۱ مقدمه

روش رایج آماری برای مدل‌سازی رابطه بین یک یا چند متغیر توضیحی با یک متغیر پاسخ دوچاله‌یا چندچاله، استفاده از مدل رگرسیون لوژستیک است. این مدل‌ها در زمینه‌های بسیاری کاربرد دارند. یکی از این زمینه‌ها تقسیم‌بندی افراد یا اشیا به دسته‌های از پیش تعیین شده بر اساس ویژگی‌های مشاهده شده در آن‌ها است که از آن تحت عنوان دسته‌بندی^۱ یاد می‌شود. در یک مدل لوژستیک دسته مربوط به هر شی توسط متغیر پاسخ و ویژگی‌های مشاهده شده نیز در قالب متغیرهای توضیحی در مسئله بیان می‌شوند، به طوری که احتمال پسین عضویت یک شی در هر دسته به وسیله یک ترکیب خطی از ویژگی‌ها مدل‌سازی و محاسبه می‌شود.

در مدل‌های لوژستیک با درنظر گرفتن اثرات خطی ویژگی‌های افراد سعی می‌شود احتمال عضویت افراد در هر دسته تعیین شود. اما گاهی در عمل ممکن است اثرات غیرخطی ویژگی‌ها (متغیرهای توضیحی) نیز در دسته‌بندی مؤثر باشند. برای حل این مسئله تلاش‌های بسیاری تا به امروز صورت گرفته است. به عنوان مثال، هستی و تیپشیرانی (۱۹۹۰) با در نظر گرفتن تبدیل‌های غیرخطی از متغیرهای توضیحی در مدل‌های لوژستیک، مدل‌های رگرسیون لوژستیک جمعی^۲ را معرفی کردند. مسئله دیگری که در پی این تلاش‌ها مورد توجه قرار گرفته این است که با وارد نمودن تبدیل‌های غیرخطی به مدل‌های لوژستیک، روش‌های برآوردهای ماقسیموم درستنمایی در این مدل‌ها لزو ما ماقسیموم سراسری را در تابع درستنمایی نتیجه نخواهد داد. از آنجا که تبدیل‌های غیرخطی باعث افزایش تعداد اکسترمهم‌های

^۱ Classification

^۲ Additive logistic regression models

موضوعی در تابع درستنما بی می شوند و از طرف دیگر تعداد این تبدیل‌ها در ابتدای نامعلوم است، لذا نحوه تعیین تعداد و ساختار بهینه تبدیل‌های غیرخطی، مسئله‌ای است که مورد توجه محققین قرار گرفته است. هرواس-مارتینز و مارتینز-استادیلو (۲۰۰۷) با در نظر گرفتن تبدیل‌های غیرخطی به صورت اثرات متقابل بین متغیرهای توضیحی در مدل‌های لوژستیک با پاسخ‌های دو حالتی، پیشنهاد کردند. در پی تلاش آن‌ها هرواس-مارتینز و همکاران (۲۰۰۸) این روش ترکیبی را برای مدل‌های لوژستیک با پاسخ‌های چندحالته‌ی تعمیم دادند. پس از آن گوتیپریز و همکاران (۲۰۱۱) نیز با در نظر گرفتن تبدیل‌های غیرخطی دیگری به صورت توابع پایه شعاعی گاوی^۳ در مدل لوژستیک، روش برآوردهای ترکیبی مشابه دیگری را مورد بررسی قرار دادند. روش‌های برآوردهای ترکیبی پیشنهاد شده توسط هرواس-مارتینز و مارتینز-استادیلو (۲۰۰۷)، هرواس-مارتینز و همکاران (۲۰۰۸) و گوتیپریز و همکاران (۲۰۱۱) به طور کلی از ترکیب سه نوع ابزار محاسباتی شبکه‌های عصبی مصنوعی^۴، الگوریتم‌های تکاملی^۵ و روش‌های ماکسیمم درستنما بی استفاده می‌کند.

شبکه‌های عصبی مصنوعی از جمله روش‌های نوین و قدرتمند محاسباتی به شمار می‌روند که با ایده‌برداری از عملکرد نرون‌های موجود در سیستم اعصاب بدن انسان به وجود آمده‌اند (هیکین، ۱۹۹۹). شبکه‌های عصبی مصنوعی لایه‌هایی از نرون‌های مصنوعی را تشکیل می‌دهند که غالباً دارای سه نوع لایه‌ی ورودی، پنهان و خروجی هستند. در هر لایه، پردازش بر روی داده‌ها به کمک توابعی به نام توابع تحریک انجام می‌شود. این شبکه‌ها بر اساس نوع تابع تحریک^۶ مورد استفاده و همچنین بر اساس تعداد لایه‌های پنهان، می‌توانند نام‌گذاری شوند. (هیکین، ۱۹۹۹). شبکه‌های عصبی مورد استفاده در روش ترکیبی هرواس-مارتینز و مارتینز-استادیلو (۲۰۰۷) و هرواس-مارتینز و همکاران (۲۰۰۸) از نوع شبکه‌های عصبی واحد

^۳ Gaussian radial basis functions

^۴ Artificial neural networks

^۵ Evolutionary algorithms

^۶ Activation function

ضربی^۷ و شبکه‌های عصبی مورد استفاده در روش ترکیبی گوتیپریز و همکاران (۲۰۱۱) از نوع شبکه‌های عصبی تابع پایه شعاعی^۸ هستند (انگلبریچت، ۲۰۰۷).

الگوریتم‌های تکاملی نیز از جمله روش‌های نوین محاسباتی در زمینه مسائل بهینه‌سازی به شمار می‌روند که با ایده‌برداری از فرایند تکامل در طبیعت به وجود آمده‌اند. یک ویژگی بارز این الگوریتم‌ها نسبت به روش‌های بهینه‌ساز کلاسیک، جمعیت محور بودن آن‌ها است، که این الگوریتم‌ها را قادر می‌سازد به طور همزمان جمعیتی از جواب‌های ممکن را در مسئله مورد بررسی قرار دهند و باعث بالا بردن توانایی آن‌ها در حل مسائلی می‌شود که دارای فضای جواب گستره و پیچیده‌ای هستند. این الگوریتم‌ها نیز دارای انواع متفاوتی هستند (انگلبریچت، ۲۰۰۷). الگوریتم تکاملی مورد استفاده در روش ترکیبی گوتیپریز و همکاران (۲۰۱۱) تحت عنوان الگوریتم برنامه‌نویسی تکاملی^۹ است که از تحقیقات فوگل (۱۹۶۲) در زمینه شبیه‌سازی تکامل سرچشمه می‌گیرد.

در این مقاله با در نظر گرفتن نوع دیگری از توابع پایه شعاعی به نام توابع چندرباعی معکوس^{۱۰} به عنوان تبدیل‌های غیرخطی از متغیرهای توضیحی، نوع دیگری از مدل‌های لوزتیک معرفی شده و با به کار بردن یک روش ترکیبی به برآوردهای پارامترها در مدل پیشنهادی پرداخته می‌شود. در مرحله اول از روش ترکیبی، ساختار و تعداد بهینه توابع چندرباعی معکوس در مدل لوزتیک به کمک تکامل یک شبکه عصبی تابع پایه شعاعی به دست می‌آید. در مرحله دوم، توابع چندرباعی معکوس حاصل، به مجموعه متغیرهای توضیحی اولیه افروزد می‌شود. در مرحله سوم با استفاده از دو الگوریتم مجزا ضرایب باقی‌مانده در مدل برآورده شوند، که هریک از این دو الگوریتم منجر به مدل‌های متفاوتی می‌شوند. الگوریتم اول تحت عنوان الگوریتم MLogistic^{۱۱} به دلیل وجود وابستگی میان متغیرهای توضیحی و تبدیل‌های غیرخطی از آن‌ها یعنی توابع چندرباعی معکوس، به

^۷ Product unit neural networks

^۸ Radial basis functions neural networks

^۹ Evolutionary programming algorithm

^{۱۰} Inverse multiquadratic functions

^{۱۱} MultiLogistic

منظور پیش‌گیری از بروز مسئله بیش‌برازش در مدل، برآوردهای ستیغی (کیسی و هویلینگن، ۱۹۹۲) را مورد محاسبه قرار می‌دهد. الگوریتم دوم نیز تحت عنوان الگوریتم Logistic^{۱۲} با استفاده از الگوریتم LogitBoost (فریدمن و همکاران، ۲۰۰۰) عمل می‌کند. این الگوریتم نیز با در نظر گرفتن یک پارامتر تنظیم به کنترل پیچیدگی مدل پرداخته و از بروز مسئله بیش‌برازش در مدل جلوگیری می‌کند.

به منظور نشان دادن عملکرد مناسب‌تر توابع پایه شعاعی چندرباعی معکوس ابتدا براساس سه مجموعه داده به مقایسه مدل‌های لوژستیک شامل توابع چندرباعی معکوس با مدل‌های لوژستیک شامل توابع پایه شعاعی گاوی پرداخته می‌شود، به طوری که به ازای هر مجموعه داده، بهترین مدل به گونه‌ای انتخاب می‌شود که دارای بیش‌ترین دقت در امر دسته‌بندی باشد. در نهایت پس از تعیین مدل‌های لوژستیک با بالاترین دقت در مجموعه داده‌های واقعی مربوط به فرایند تولید ورقه‌های فولاد، به بررسی ساختار آن مدل‌ها پرداخته می‌شود.

در بخش ۲ مدل‌های لوژستیک شامل توابع پایه شعاعی چندرباعی معکوس معرفی می‌شود. در بخش ۳ با معرفی روش ترکیبی پیشنهاد شده توسط گوتیرز و همکاران (۲۰۱۱)، به برآوردهایی پارامترهای این مدل‌ها پرداخته می‌شود. در بخش ۴ با استفاده از سه مجموعه داده، دقت دسته‌بندی مدل‌های پیشنهادی با دقت دسته‌بندی مدل‌های لوژستیک شامل توابع گاوی مورد مقایسه قرار می‌گیرد. در بخش ۵ نیز ساختار بهترین مدل‌های لوژستیک در مجموعه داده‌های واقعی تشریح می‌شود. در بخش ۶ مدت زمان مورد نیاز برای اجرای روش ترکیبی بیان می‌شود و در بخش پایانی، بحث و نتیجه‌گیری ارائه می‌شود.

۲ معرفی مدل LIIM

در مسئله دسته‌بندی مجموعه مشاهدات $D = \{(x_n, y_n), n = 1, \dots, N\}$ ، بردار $x_n = (x_{n1}, \dots, x_{nk})$ نشان دهنده مقادیر k ویژگی مشاهده شده مربوط به فرد یا شئ n ام و بردار $y_n = (y_n^{(1)}, \dots, y_n^{(J)})$ نشان دهنده دسته‌ای است که فرد یا

^{۱۲} SimpleLogistic

۱۳۰ توابع چندربعی معکوس به عنوان اثرات غیرخطی

شیء n ام در بین J دسته، به آن تعلق دارد، به طوری که $1 = y_n^{(\ell)}$ اگر فرد n ام به دسته‌ی ℓ تعلق داشته باشد و در غیر این صورت $0 = y_n^{(\ell)}$. مدل‌های لوژستیک در مسائل دسته‌بندی، با فرض وجود J دسته و با در نظر گرفتن یک ترکیب خطی از ویژگی‌های مشاهده شده، رابطه بین ویژگی‌ها و احتمال عضویت فرد با بردار ویژگی x به دسته‌ی ℓ ام را به صورت

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(J)} = 1|x)} = \alpha_0^\ell + \alpha_1^\ell x_1 + \dots + \alpha_k^\ell x_k, \quad \ell = 1, \dots, J. \quad (1)$$

مدل‌سازی می‌کنند، که در این روش فرد با بردار ویژگی x به دسته j اختصاص می‌یابد اگر (وب، ۲۰۰۲):

$$\ln P(y^{(j)} = 1|x) = \max_{\ell} P(y^{(\ell)} = 1|x), \quad \ell = 1, \dots, J.$$

گاهی در عمل ممکن است علاوه بر اثرات خطی، اثرات غیرخطی ویژگی‌ها نیز در مسئله دسته‌بندی و در نتیجه در مدل رگرسیون لوژستیک نقش مؤثری داشته باشند. گوتیپریز و همکاران (۲۰۱۱) اثرات غیرخطی را در مدل‌های لوژستیک به صورت توابع پایه شعاعی گاوی در نظر گرفتند. توابع پایه شعاعی، دارای مقادیری متقارن حول یک مرکز، با یک شعاع مشخص هستند. مقدار این توابع در هر نقطه تنها به فاصله آن تا مرکز بستگی دارد. یک نوع از این توابع، با عنوان توابع پایه شعاعی گاوی به صورت

$$f(\|x - c\|) = \exp\left(-\frac{\|x - c\|^2}{r^2}\right)$$

تعريف می‌شود و نوع دیگر آن‌ها تابع چندربعی معکوس به صورت

$$f(\|x - c\|) = \frac{1}{\sqrt{r^2 + \|x - c\|^2}}$$

است، که در آن‌ها مرکز c و شعاع تابع تابع است و در هر دو تابع با افزایش فاصله از مرکز c کاهش می‌باشد. با وارد نمودن m تبدیل غیرخطی به صورت توابع چندربعی معکوس به رابطه (۱) مدل لوژستیک پیشنهادی به صورت

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(J)} = 1|x)} = \alpha_0^\ell + \sum_{i=1}^k \alpha_i^\ell x_i + \sum_{j=1}^m \frac{\beta_j^\ell}{\sqrt{r_j^2 + \|x - c_j\|^2}}, \quad \ell = 1, \dots, J \quad (2)$$

حاصل می شود که تحت عنوان مدل LIIM^{۱۳} نام گذاری می شود. دلیل استفاده از توابع گاوی و چندرباعی معکوس در مدل های لوژستیک به عملکرد این توابع در مسائل دسته بندی مربوط می شود. مقدار این توابع به ازای یک بردار ویژگی x و یک شعاع مشخص r ، با افزایش فاصله x از مرکز ثابت c ، کاهش می یابد. این کاهش می تواند در روش های دسته بندی به گونه ای استفاده شود که منجر به کاهش احتمال عضویت فرد در دسته ای شود که به آن تعلق ندارد که این امر، خود مشروط بر انتخاب مناسب مرکز و شعاع در تابع است. بنابراین توابع پایه شعاعی گاوی و چندرباعی معکوس می توانند در دسته بندی صحیح افراد و در نتیجه در مدل های لوژستیک نقش مؤثری داشته باشند.

۳ روش برآوردهای ترکیبی در مدل LIIM

در مدل های لوژستیک محمولًا با روش های تکرار شونده ای^{۱۴} مانند نیوتون-رافسون^{۱۵}، به محاسبه برآوردهای ماکسیمم درستنمایی پارامترها پرداخته می شود (اگرستی، ۲۰۰۲). در مدل (۲)، منفی لگاریتم تابع درستنمایی به صورت

$$\begin{aligned} L(\theta) &= - \sum_{n=1}^N \ln P(y_n = 1 | x_n) \\ &= - \sum_{n=1}^N \left[\sum_{\ell=1}^{J-1} y_n^{(\ell)} f_{\ell}(x_n, \theta_{\ell}) - \ln \sum_{\ell=1}^{J-1} \exp \{f_{\ell}(x_n, \theta_{\ell})\} \right] \quad (3) \end{aligned}$$

است، که در آن

$$f_{\ell}(x_n, \theta_{\ell}) = \alpha_{\circ}^{\ell} + \sum_{i=1}^k \alpha_i^{\ell} x_{in} + \sum_{j=1}^m \frac{\beta_j^{\ell}}{\sqrt{r_j^2 + \|x_n - c_j\|^2}}, \quad \ell = 1, \dots, J-1 \quad (4)$$

و $(\alpha_{\circ}^{\ell}, \dots, \alpha_k^{\ell})$ ماتریس پارامترهای تابع f_{ℓ} است. $\theta_{\ell} = (\alpha^{\ell}, \beta^{\ell}, W)$ و $\alpha^{\ell} = (\alpha_{\circ}^{\ell}, \dots, \alpha_k^{\ell})$ ضرایب در مدل و $\beta^{\ell} = (\beta_1^{\ell}, \dots, \beta_m^{\ell})$ ماتریسی با درایه های $W = (w_1, \dots, w_m)$ باشد. $w_j = (c_{j1}, \dots, c_{jk})$ مرکز و r_j شعاع در j امین

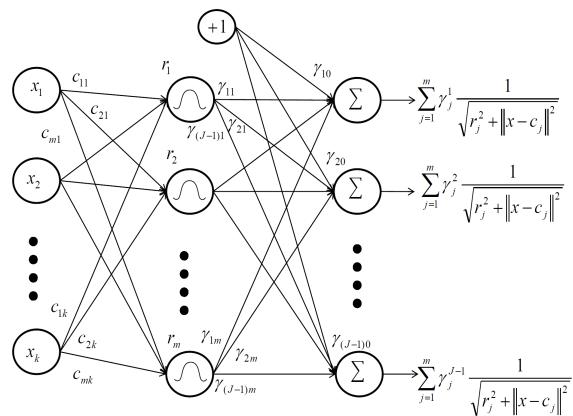
^{۱۳} Logistic Initial Inverse Multiquadratic

^{۱۴} Iterative methods

^{۱۵} Newton-Raphson

تابع چندرباعی معکوس هستند و برای هر i و j , $c_{ij} \in R$ و $r_j \in R^+$. وجود قسمت غیرخطی $\sum_{j=1}^m \beta_j^\ell \frac{1}{\sqrt{r_j^2 + \|x_n - c_j\|^2}}$ در تابع (۴) از یک طرف باعث افزایش تعداد اکسیترم‌های موضعی در تابع درستنمایی شده و از طرف دیگر نامعلوم بودن تعداد بهینه توابع چندرباعی معکوس باعث ناتوانی روش‌های معمول برآوردهای ماکسیمم درستنمایی در محاسبه مینیمم سراسری تابع (۳) شده و برآوردهای پارامترها را با مشکل موافق می‌سازد. این دلایل می‌توانند انگیزه‌های مناسی برای استفاده از یک روش ترکیبی به منظور برآوردهای پارامترها در چنین مدلی به شمار روند.

در روش ترکیبی برای برآوردهای پارامترهای مدل LIIM، در مرحله اول تعداد و ساختار بهینه توابع چندرباعی معکوس، به کمک تکامل یک شبکه عصبی تابع پایه شعاعی به دست می‌آیند. به این منظور ابتدا، قسمت غیرخطی مدل پیشنهادی (۲)، تعداد نرون‌های لایه پنهان و r_j ها وزن‌ها در اتصالات لایه ورودی به لایه پنهان در نظر گرفته می‌شوند. همچنین نرون‌ها در لایه پنهان به کمک توابع تحریک چندرباعی معکوس، وظیفه پردازش داده‌ها را بر عهده دارند. در لایه خروجی نیز نرون‌ها با دریافت خروجی‌های مربوط به لایه پنهان، به عنوان ورودی‌های خود و همچنین با دریافت وزن‌هایی، حاصل جمع وزنی ورودی‌ها را به عنوان خروجی‌های شبکه محاسبه می‌کنند. شکل ۱ این شبکه را نمایش می‌دهد. هدف از نمایش قسمت



شکل ۱: شبکه عصبی تابع پایه شعاعی

غیرخطی مدل (۲) توسط شبکه، تعیین تعداد و ساختار بهینه تبدیل‌های غیرخطی به کمک تکامل شبکه است. به بیان دیگر تعیین وزن‌ها و همچنین تعداد نرون‌های لایه پنهان یعنی m در این شبکه طی فرایند تکامل شبکه انجام می‌پذیرد. فرایند تکامل شبکه با استفاده از الگوریتم برنامه‌نویسی تکاملی انجام می‌شود. این الگوریتم مانند دیگر الگوریتم‌های تکاملی، جواب‌های ممکن در یک مسئله را به عنوان افراد در یک جمعیت در نظر می‌گیرد. سپس براساس یک جمعیت اولیه از این افراد و با به کار بردن عملگرهای تکاملی در هر مرحله، باعث بهبود افراد (جواب‌های) موجود در این جمعیت می‌شود. این مراحل در الگوریتم‌های تکاملی تا برقراری یک یا چند شرط خاتمه تکرار شده و در پایان، بهترین فرد در جمعیت نهایی به عنوان جواب بهینه در مسئله انتخاب می‌شود (انگلبریچت، ۲۰۰۷).

الگوریتم برنامه‌نویسی تکاملی مورد استفاده در روش ترکیبی با هدف تعیین بهترین شبکه عصبی تابع پایه شعاعی، برمنای یک جمعیت تصادفی اولیه از این نوع شبکه‌ها عمل می‌کند و با در نظر گرفتن منفی لگاریتم تابع درستنمایی به عنوان معیار خطای، سعی می‌کند در هر مرحله، ساختار و پارامترهای شبکه‌های عصبی در این جمعیت را در جهت مینیمم‌سازی این معیار، بهبود بخشد. در هر مرحله از این الگوریتم، عملگر جهش پارامتری برای تغییر و بهبود وزن‌ها و جهش ساختاری به منظور تغییر تعداد نرون‌های لایه پنهان (m)، استفاده می‌شوند و یک جمعیت جدید از شبکه‌های عصبی تابع پایه شعاعی را تولید می‌کنند. این مراحل تا رسیدن به یک یا چند شرط خاتمه تکرار می‌شود (گوتییرز و همکاران، ۲۰۱۱). پس از برقراری شروط خاتمه، شبکه عصبی تابع پایه شعاعی که در جمعیت نهایی، دارای کمترین مقدار خطای باشد به عنوان بهترین شبکه انتخاب می‌شود. به این ترتیب تعداد و ساختار بهینه توابع چندربعی معکوس در فرایند تکامل شبکه عصبی تابع پایه شعاعی تعیین می‌شود. پس از تعیین پارامترهای مرکز و شعاع و تعداد توابع چندربعی معکوس، در مرحله دوم، توابع چندربعی معکوس به دست آمده، به صورت متغیرهای توضیحی جدید (زجهای) در مدل در نظر گرفته می‌شوند و مدل حاصل

به صورت

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(J)} = 1|x)} = \alpha_0^\ell + \sum_{i=1}^k \alpha_i^\ell x_i + \sum_{j=1}^m \beta_j^\ell z_j, \quad \ell = 1, \dots, J \quad (5)$$

بازنویسی می‌شود. در مرحلهٔ نهایی، برای برآورد بقیهٔ ضرایب، یعنی α_i ها و β_j ها، از دو الگوریتم مجزا استفاده می‌شود. در الگوریتم اول تحت عنوان الگوریتم MLogistic بر اساس روش پیشنهاد شدهٔ توسط کیسی و هویلینگن (۱۹۹۲)، با افزودن یک عبارت جریمه‌ای به رابطهٔ (۳) به صورت $L^\lambda(\gamma) = L(\gamma) - \lambda \|\gamma\|^2$ برآوردگرهای ستیغی^{۱۶} ضرایب محاسبه می‌شوند، که در آن $(\alpha', \beta') = \lambda$ پارامتر ستیغی یا پارامتر تنظیم نامیده شده و باعث تنظیم پایداری برآوردهای حاصل می‌شود به گونه‌ای که به ازای $\lambda = 0$ برآوردهای ضرایب همان برآوردهای ماکسیمم درستنمایی معمولی هستند در حالی که وقتی $\lambda \rightarrow \infty$ برآوردهای تمام ضرایب به سمت صفر می‌کنند.

الگوریتم دوم تحت عنوان SLogistic بر مبنای الگوریتم LogitBoost در برآذش مدل‌های لوژستیک جمعی معرفی شدهٔ توسط فریدمن (۲۰۰۰) عمل می‌نماید. این الگوریتم مانند یک روش گام به گام پیش‌رونده^{۱۷} به انتخاب بین متغیرهای توضیحی اولیه و توابع چندرباعی معکوسی که بیشترین ارتباط را با مقادیر پاسخ دارند، می‌پردازد. انتخاب در این الگوریتم بر مبنای معیار کمترین توانهای دوم خطای (SE) از ورود متغیرهای توضیحی که باعث ایجاد مسئلهٔ بیشبرازش در مدل شده و ناپایداری را در بین برآوردها در پی دارند، جلوگیری به عمل می‌آورد:

$$SE^\lambda = SE - \lambda \|\gamma\|$$

جزئیات الگوریتم‌های MLogistic و SLogistic توسط گوتییرز و همکاران (۲۰۱۱) ارائه شده است. محاسبهٔ پارامتر تنظیم λ در هر دو الگوریتم با استفاده از مجموعهٔ مقادیر $\{10^{-2}, 10^{-1.5}, \dots, 10^{-0.5}\}$ و روش اعتبار سنجی متقابل ۱۰-بخشی^{۱۸}

^{۱۶} Ridge estimators

^{۱۷} Forward stepwise

^{۱۸} 10-fold cross validation

انجام می‌پذیرد به طوری که هر بار با انتخاب یک مقدار در این مجموعه و اجرای روش اعتبار سنجی به ازای آن مقدار، میانگین خطای دسته‌بندی محاسبه می‌شود. در نهایت مقداری از این مجموعه که به ازای آن کمترین میانگین خطای به دست آمده، به عنوان مقدار مناسب برای پارامتر λ انتخاب می‌شود. در اجرای روش اعتبار سنجی متقابل ۱۰-بخشی ابتدا مجموعه داده به ۱۰ زیر مجموعه مجزا و تقریباً برابر تقسیم می‌شود، سپس هر بار یک زیر مجموعه به عنوان مجموعه آزمایشی برای محاسبه خطای مجموعه دیگر به منظور مدل‌سازی و برآورد پارامتر در نظر گرفته می‌شوند. این فرایند تا جایی ادامه می‌یابد که هر بخش از داده‌ها یک بار به عنوان مجموعه آزمایشی مورد استفاده قرار گرفته باشد.

پس از اجرای هر یک از دو الگوریتم MLogistic و SLogistic مدل‌های لوزستیک متفاوتی حاصل می‌شوند به طوری که با در نظر گرفتن همه متغیرهای توضیحی اولیه و توابع چندرباعی معکوس به دست آمده در مرحله اول و اعمال دو الگوریتم SLogistic و MLogistic به صورت مجزا، مدل‌های حاصل به ترتیب^{۱۹} MLIIM و SLIIM^{۲۰} نام‌گذاری می‌شوند. ساختار کلی این دو مدل به صورت

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(J)} = 1|x)} = \alpha_0^\ell + \sum_{i=1}^k \alpha_i^\ell x_i + \sum_{j=1}^m \beta_j^\ell \frac{1}{\sqrt{r_j + \|x - c_j\|^2}}, \quad \ell = 1, \dots, J$$

است، با این تفاوت که ضرایب α_i و β_j در این دو مدل به ترتیب با الگوریتم‌های SLogistic و MLogistic و برآورد می‌شوند. با در نظر گرفتن تنها توابع چندرباعی معکوس (رژهای) و اعمال نمودن دو الگوریتم MLogistic و SLogistic به صورت مجزا برای برآورد ضرایب، مدل‌های حاصل به ترتیب MLIM و SLIM نام‌گذاری می‌شوند و دارای ساختار کلی

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(J)} = 1|x)} = \alpha_0^\ell + \sum_{j=1}^m \beta_j^\ell \frac{1}{\sqrt{r_j + \|x - c_j\|^2}}, \quad \ell = 1, \dots, J$$

هستند، که تنها تفاوت آن‌ها نیز در برآورد ضرایب α_i و β_j است.

^{۱۹} MultiLogistic Initial inverse multiquadratic

^{۲۰} SimpleLogistic Initial Inverse Multiquadratic

۴ آزمایشات تجربی

در این بخش مدل‌های لوژستیک پیشنهادی به سه مجموعه داده برآش داده می‌شود. سپس به مقایسه و ارزیابی این مدل‌ها با مدل‌های لوژستیک شامل توابع پایه شعاعی گاوی پرداخته می‌شود. در مجموعه داده اول، تحت عنوان مجموعه داده تشخیص بیماری قلبی^{۲۱}، به بررسی عوامل مؤثر بر وجود یا عدم بیماری قلبی در افراد پرداخته می‌شود. این مجموعه شامل ۳۰۲ مشاهده است که متغیر پاسخ بیان‌کننده وجود یا عدم بیماری قلبی در افراد و متغیرهای توضیحی بیان‌کننده میزان کلسترول، قندخون و سایر نتایج آزمایشگاهی مربوط به هر فرد است. در مجموعه داده‌های دوم و سوم با استفاده از یک نمونه به حجم ۱۰۰۰ از تولیدات داخلی ورقه‌های فولادی در یک کارخانه به بررسی معاایب در این ورقه‌ها پرداخته می‌شود. به این منظور خواص مکانیکی و آزمایشگاهی ورقه‌های تولیدی به عنوان متغیرهای توضیحی منظور می‌شوند. خواص مکانیکی ورقه‌ها مانند استحکام کشش نهایی، ضخامت آنها و خواص آزمایشگاهی ورقه‌ها مانند میزان کربن، سیلیکون، منیزیم و مواد به کار رفته‌ی دیگر در تولید ورقه‌ها در نظر گرفته می‌شوند. مجموعه داده دوم تحت عنوان مجموعه نورد، مهم‌ترین نوع عیوب را در بین ورقه‌های معیوب و سالم مورد بررسی قرار می‌دهد، یعنی متغیر پاسخ چندحالتسی است که نوع عیوب در ورقه‌ها را بیان می‌کند. در مجموعه داده سوم تحت عنوان مجموعه نورد دودوئی، تنها معیوب و سالم بودن ورقه‌ها مورد توجه قرار می‌گیرند، یعنی متغیر پاسخ دوحالتسی است.

ارزیابی مدل‌ها با روش اعتبارسنجی متقابل ۱۰-بخشی انجام می‌شود که به منظور افزایش دقت در نتایج، در هر بخش، طراحی و آزمایش مدل‌ها، ۳ بار تکرار می‌شود. نرخ دسته بندهی صحیح^{۲۲} در هر بار آزمایش به عنوان شاخص دقت در مدل اندازه‌گیری می‌شود. این شاخص برابر با نسبت مواردی است که توسط مدل،

^{۲۱} <http://www.uco.es/ayrna/index.php?lang=en>

^{۲۲} Correct classification rate

آرزو مجبری و همکاران ۱۳۷.....

به درستی دسته‌بندی شده است و به صورت

$$CCR = \frac{1}{N} \sum_{i=1}^N I(C(x_n) = y_n)$$

محاسبه می‌شود، که در آن $C(x_n)$ نشان دهنده دسته‌ای است که توسط مدل به فرد یا شیء n ام اختصاص می‌یابد و $I(\cdot)$ نشان دهنده تابع نشان‌گری است که اگر $C(x_n) = y_n$ آن‌گاه مقدار این تابع برابر با یک و در غیر این صورت برابر با صفر است. پس از اجرای همه ۳۰ آزمایش، میانگین و انحراف معیار نرخ‌های دسته‌بندی صحیح بر حسب درصد محاسبه می‌شود.

جدول ۱ میانگین (انحراف معیار) شاخص دقت مورد نظر را برای مدل‌های لوژستیک پیشنهادی و مدل‌های لوژستیک شامل توابع گاووسی در ۳۰ آزمایش انجام شده را نمایش می‌دهد. مدل‌های SLIRBF، MLIRBF و SLIRBF مدل‌های لوژستیکی هستند که تبدیل‌های غیرخطی در آن‌ها، از نوع توابع گاووسی است. برآوردهای پارامترها در این مدل‌ها به ترتیب متناظر با مدل‌های پیشنهادی است. برآوردهایی پارامترها در این مدل‌ها به ترتیب متناظر با مدل‌های SLIM و MLIM است (گوتیز و همکاران، ۲۰۱۱).

جدول ۱: میانگین و (انحراف معیار) شاخص‌های دقت

مدل								مجموعه داده بیماری قلبی
SLIRBF	SLIIM*	SLRBF	SLIM*	MLIRBF	MLIIM*	MLRBF	MLIM*	
۸۴/۱۹ (۶/۲۸)	۸۴/۳۰ (۶/۴۱)	۸۲/۸۷ (۶/۹۶)	۷۶/۵۷ (۵/۳۶)	۸۳/۷۵ (۶/۸۲)	۸۴/۷۶ (۷/۱۰)	۸۴/۱۶ (۶/۸۳)	۷۵/۸۰ (۵/۸۹)	نورد
۶۲/۸۷ (۲/۸۵)	۶۳/۲ (۲/۲۳)	۶۱/۸۷ (۲/۵۶)	۶۱/۹۳ (۲/۸۵)	۶۳/۹ (۲/۳۵)	۶۳/۳۳ (۲/۹۴)	۶۲/۱۰۳ (۲/۵۴)	۶۱/۹۳ (۲/۹۲)	نورد
۷۶/۸۹ (۶/۰۶)	۷۸/۸۳ (۴/۴۰)	۷۵/۶۷ (۶/۶۶)	۷۸/۲۳ (۴/۰۱)	۷۵/۵۶ (۵/۸۲)	۷۸/۲ (۴/۴۴)	۷۵/۱۷۸ (۶/۷۲)	۷۸/۱۳ (۴/۷۰)	نورد دوغونه

* مدل‌های پیشنهادی

در مقایسه‌ی میانگین و انحراف معیار شاخص‌های دقت مندرج در جدول ۱ برای مدل‌های لوژستیک پیشنهادی با مدل‌های لوژستیک دربردارنده توابع گاووسی، نتایج زیر به تفکیک مجموعه‌های داده حاصل می‌شوند:

- در مجموعه داده بیماری قلبی، مدل‌های MLIIM و SLIIM (به ترتیب با مقادیر ۸۴/۷۶ و ۸۴/۳۰) دارای میانگین نرخ دسته‌بندی صحیح بالاتری نسبت

۱۳۸ توابع چندربعی معکوس به عنوان اثرات غیرخطی

به مدل‌های لوژستیک شامل توابع گاووسی متناظر یعنی مدل‌های MLIRBF و SLIRBF (به ترتیب با مقادیر ۸۴/۷۵ و ۸۴/۱۹) هستند.

- در مجموعه داده نورد، مدل‌های SLIM و SLIIM (به ترتیب با مقادیر ۶۱/۹۳ و ۶۳/۲) دارای میانگین نرخ دسته‌بندی صحیح بالاتری نسبت به مدل‌های لوژستیک شامل توابع گاووسی متناظر یعنی مدل‌های SLIRBF و SLRBF (به ترتیب با مقادیر ۶۱/۸۷ و ۶۲/۸۷) هستند.

- در مجموعه داده نورد دودوئی، مدل‌های MLIIM، MLIM و SLIIM (به ترتیب با مقادیر ۷۸/۱۳، ۷۸/۲۳، ۷۸/۲ و ۷۸/۸۳) دارای میانگین نرخ دسته‌بندی صحیح بالاتری نسبت به مدل‌های لوژستیک شامل توابع گاووسی متناظر یعنی مدل‌های SLIRBF، MLIRBF و SLRBF (به ترتیب با مقادیر ۷۵/۷۸، ۷۵/۵۶، ۷۵/۶۷ و ۷۶/۸۹) هستند.

بار دیگر با مشاهده جدول ۱ می‌توان دریافت که در بین ۸ مدل برآش شده:

- در مجموعه داده بیماری قلبی، مدل MLIIM (با مقدار ۸۴/۷۶) دارای بالاترین شاخص دقت است. به بیان دیگر این مدل در ۸۴/۷۶ درصد موارد توانسته است وجود یا عدم بیماری قلبی را در افراد مورد آزمایش، به درستی تشخیص دهد.

- در مجموعه داده نورد، مدل MLIRBF (با مقدار ۶۳/۹) دارای بالاترین شاخص دقت است. به بیان دیگر این مدل در ۶۳/۹ درصد موارد توانسته است نوع عیب را در ورقه‌های فولادی، به درستی تشخیص دهد. نکته جالب توجه این که مدل پیشنهادی MLIIM نیز متناظر با اختلاف اندکی در رتبه دوم قرار دارد.

- در مجموعه داده نورد دودوئی، مدل SLIIM (با مقدار ۷۸/۸۳) با اختلاف نسبتاً زیادی دارای بالاترین شاخص دقت است. به بیان دیگر این مدل در ۷۸/۸۳ درصد موارد توانسته است معیوب یا سالم بودن ورقه‌های فولادی را به درستی تشخیص دهد.

۵ ساختار مدل‌های لوژستیک مربوط به داده‌های واقعی

همان‌طور که در بخش قبل گفته شد، مدل‌های MLIRBF و SLIIM به ترتیب در مجموعه داده‌های واقعی نورد و نورد دو دوئی دارای بالاترین میانگین نرخ دسته‌بندی صحیح در بین ۸ مدل معرفی شده هستند. در این بخش به بیان ساختار هریک از این دو مدل پرداخته می‌شود. مدل‌های برآش یافته در این بخش با اجرای روش ترکیبی و با استفاده از کل داده‌ها در هر مجموعه داده، به دست آمدند.

• مدل MLIRBF در مجموعه داده نورد:

هدف استفاده از ویژگی‌های مشاهده شده مربوط به ورقه‌های تولید شده مانند خواص آزمایشگاهی و مکانیکی آن‌ها به منظور تشخیص نوع عیوب در این ورقه‌ها است. در این مجموعه داده، مهم‌ترین نوع معایب با کدهای $\ell = 1, \dots, 6$ و سالم بودن ورقه با کد $\ell = 7$ نمایش داده شده است. پس از اجرای روش ترکیبی بر روی کل داده‌ها در این مجموعه و برآش مدل MLIRBF نرخ دسته‌بندی صحیح برابر با $63/9$ درصد به دست می‌آید. ساختار کلی مدل برآش یافته به صورت

$$\ln \frac{P(y^{(\ell)} = 1|x)}{P(y^{(7)} = 1|x)} = \alpha_0^\ell + \sum_{i=1}^4 \alpha_i^\ell x_i + \sum_{j=1}^4 \beta_j^\ell z_j, \quad \ell = 1, \dots, 6 \quad (6)$$

است، که در آن z_j ‌ها مقادیر مربوط به توابع گاوسی حاصل از روش ترکیبی هستند و به عنوان متغیرهای توپیچی جدید (z_j ‌ها) در نظر گرفته می‌شوند. برآورد ضرایب α_i ‌ها و β_j ‌ها در جدول ۲ آورده شده است.

• مدل SLIIM در مجموعه داده نورد دودوئی:

هدف، استفاده از ویژگی‌های مربوط به ورقه‌های تولید شده مانند خواص آزمایشگاهی و مکانیکی آن‌ها به منظور تعیین معیوب یا سالم بودن ورقه‌ها است. در این مجموعه داده، ورقه‌های معیوب با کد صفر و ورقه‌های سالم با کد یک مشخص شده‌اند. پس از اجرای روش ترکیبی بر روی کل داده‌ها در این مجموعه، مدل SLIIM برآش یافته دارای نرخ دسته‌بندی صحیح برابر با

جدول ۲: برآورده ضرایب در مدل (۶)

j	ضریب	متغیر توضیحی
۶	α_6^j	x_6 (ضخامت ورق)
۵	α_5^j	x_5 (تیم کاری A)
۴	α_4^j	x_4 (تیم کاری B)
۳	α_3^j	x_3 (تیم کاری C)
۲	α_2^j	x_2 (تیم کاری D)
۱	α_1^j	x_1 (شیفت کاری ۱)
		x_7 (شیفت اری ۲)
		x_8 (شیفت کاری ۳)
		x_9 (روغن امولسیون)
		x_{10} (ناهمواری سطح)
		x_{11} (وزن کل ورق)
		x_{12} (نقطه‌ی تسليم)
		x_{13} (استحکام کشش نهایی)
		x_{14} (میزان کشش ورق)
		x_{15} (سختی مرکز ورق)
		x_{16} (میزان کرین)
		x_{17} (میزان سلیکون)
		x_{18} (میزان منیزیم)
		x_{19} (میزان آلومنیوم)
		x_{20} (میزان نیتروژن)
		x_{21} (میزان وانادیوم)
		x_{22} (میزان تیتانیوم)
		x_{23} (میزان سولفور)
		x_{24} (میزان فسفر)
		z_1
		z_2
		z_3
		z_4
		عرض از مبدأ

۷۹ درصد است. ساختار کلی مدل برآراش یافته به صورت

$$\ln \frac{P(y^{(1)} = 1|x)}{P(y^{(0)} = 1|x)} = \alpha_0^1 + \sum_{i=1}^{24} \alpha_i^1 x_i + \sum_{j=1}^7 \beta_j^1 z_j. \quad (V)$$

است، که در آن z_j ها مقادیر مربوط به توابع چندربعی معکوس حاصل از روش ترکیبی هستند و به عنوان متغیرهای توضیحی جدید در نظر گرفته می‌شوند. برآورده ضرایب α_i ها و β_j ها در جدول ۳ آورده شده است.

جدول ۳: برآورد ضرایب در مدل (۷)

$j = 1$	ضریب	متغیر توضیحی
۰/۱۲	α_1^j	(ضخامت ورق) x_1
-۰/۱۰۱	α_2^j	(تیم کاری A) x_2
۰/۰۹۰	α_3^j	(تیم کاری B) x_3
۰/۲۰۲	α_4^j	(تیم کاری C) x_4
-۰/۱۷۷	α_5^j	(تیم کاری D) x_5
۰/۰۳۵	α_6^j	(شیفت کاری ۱) x_6
۰/۰۴۴	α_7^j	(شیفت اری ۲) x_7
-۰/۱۲۵	α_8^j	(شیفت کاری ۳) x_8
۰/۰۰۵	α_9^j	(روغن امولسیون) x_9
-۰/۱۹۲	α_{10}^j	(ناهمواری سطح) x_{10}
-۰/۰۵۴	α_{11}^j	(وزن کل ورق) x_{11}
۱/۸۷۲	α_{12}^j	(نقطه‌ی تسایم) x_{12}
-۰/۳۷۶	α_{13}^j	(استحکام کشن نهایی) x_{13}
۱/۰۸۰	α_{14}^j	(میزان کشش ورق) x_{14}
۰/۳۲۱	α_{15}^j	(سختی مرکز ورق) x_{15}
-۰/۱۸۵	α_{16}^j	(میزان کرن) x_{16}
-۰/۰۳۳	α_{17}^j	(میزان سیلیکون) x_{17}
۰/۰۵۹	α_{18}^j	(میزان منیزیم) x_{18}
۰/۰۳۱	α_{19}^j	(میزان آلومنیوم) x_{19}
۰/۰۰۱	α_{20}^j	(میزان نیتروژن) x_{20}
۰/۰۰۳	α_{21}^j	(میزان وانادیوم) x_{21}
-۰/۲۱۷	α_{22}^j	(میزان تیتانیوم) x_{22}
۰/۱۲۱	α_{23}^j	(میزان سولفور) x_{23}
-۰/۶۹۷	α_{24}^j	(میزان فسفر) x_{24}
-۹/۹۳۲	β_1^j	z_1
-۱۳/۸۱۳	β_2^j	z_2
۲۷/۱۳۹	β_3^j	z_3
-۲/۶۱۴	β_4^j	z_4
۲/۸۸۸	β_5^j	z_5
۲۳/۰۳۸	β_6^j	z_6
-۰/۰۵۴	α_0^j	عرض از مبدأ

۶ تخمین مدت زمان محاسباتی

جدول ۴ به طور تقریبی مدت زمان‌های مورد نیاز (برحسب ساعت) برای اجرای کامل آزمایشات مربوط به بخش ۴ را به تفکیک مدل‌ها نشان می‌دهد. روش ترکیبی با استفاده از دو نرم افزار MatlabR2012a و WEKA اجرا شده است به طوری که مرحله اول این روش، یعنی اجرای الگوریتم برنامه‌نویسی تکاملی در محیط برنامه‌نویسی Matlab و اجرای دو الگوریتم MLogistic و SLogistic در محیط WEKA انجام پذیرفته است. نتایج ارائه شده در جدول ۲ براساس سیستم ۸ Core

. ۳.۰۰-GHz Intel Xeon(R) X5450 CPUs با حافظه ۱۲ گیگا بایت ۶۴ بیتی است.

جدول ۴: تخمین مدت زمان محاسبات

مجموعه داده									مدل
SLIRBF	SLIIM*	SLRBF	SLIM*	MLIRBF	MLIIM*	MLRBF	MLIM*		
۱۶۹	۲۴	۱۶۹	۲۴	۱۶۸	۲۴	۱۶۸	۲۴	بیماری قلبی	
۲۴	۹۶	۲۴	۹۶	۲۴	۹۶	۲۴۱	۹۶	نورد	
۱۶۱	۴۸	۱۶۱	۴۸	۱۶۰	۴۸	۱۶۰	۴۸	نورد دودوئی	*
مدل‌های پیشنهادی									

بحث و نتیجه گیری

در این مقاله به معرفی یک روش دستیه‌بندی با استفاده از مدل‌های لوژستیکی پرداخته شد که این مدل‌ها شامل تبدیل‌های غیرخطی از متغیرهای توضیحی، به صورت توابع چندربعدی معکوس هستند. به منظور برآورد دیابی پارامترهای مدل‌های پیشنهادی، روشی ترکیبی موردن استفاده قرار گرفت و مدل‌های برآش یافته با مدل‌های لوژستیکی که شامل توابع گاووسی هستند، بر اساس سه مجموعه داده، مورد ارزیابی و مقایسه قرار گرفتند. نتایج آزمایشات حاکی از مؤثر بودن نقش توابع چندربعدی معکوس نسبت به توابع گاووسی، در بسیاری از موارد بوده است.

تقدیر و تشکر

نویسنده‌گان از اعضای محتشم هیئت تحریریه و داوران گرامی مجله تشکر و قدردانی می‌نمایند.

مراجع

Agresti, A. (2002), *Categorical Data Analysis*, 2nd Ed., John Wiley and Sons, New York.

آرزو مجبری و همکاران ۱۴۳

Cessie, S. and Houwelingen, J. (1992), Ridge Estimators in Logistic Regression, *Applied Statistics*, **41**, 191-201.

Engelbrecht, A. P. (2007), *Computational Intelligence*, John Wiley and Sons, New York.

Friedman, J., Hastie, T. and Tibshirani, R. (2000), Additive Logistic Regression: A Statistical View of Boosting, *Annals of Statistics*, **38**, 337-374.

Fogel, L. J. (1962), Autonomous Automata, *Industrial Research*, **4**, 14-19.

Gutierrez, P. A., Hervas-Martinez, C. and Martinez-Estudillo, F. J. (2011), Logistic Regression by Means of Evolutionary Radial Basis Function Neural Networks, *IEEE Transactions on Neural Networks*, **22**, 246-263.

Hastie, T. J. and Tibshirani, R. J. (1990), *Generalized Additive Models*, Chapman & Hall.

Haykin, S. (1999), *Neural Networks: A Comprehensive Foundation*, 2nd Ed., Pearson Education.

Hervas-Martinez, C. and Martinez-Estudillo, F. J. (2007), Logistic Regression Using Covariates Obtained by Product Unit Neural Networks, *Pattern Recognition*, **40**, 52-64.

Hervas-Martinez, C., Martinez-Estudillo, F. J. and Carbonero-Ruz, M. (2008), MultiLogistic Regression by Means of Evolutionary Product Unit Neural Networks, *Neural Networks*, **21**, 951-961.

Webb, A. R. (2002), *Statistical Pattern Recognition*, John Wiley and Sons, New York.