



طراحی مدل تشخیصی HTLV1 با استفاده از شمارش کامل سلول‌های خونی

معصومه سرباز^{*}، امید پورنیک، لیلا قالیچی، خلیل کیمیافر، امیررضا رضوی

^{*}دانشجوی دکترای انفورماتیک پزشکی عضو هیئت علمی دانشکده علوم پیاپیشکی مشهد

sarbazm@mums.ac.ir

چکیده

عفونت با ویروس HTLV-I که در بعضی از نقاط ایران به صورت اندمیک دیده می‌شود در اکثر موارد بدون علامت بوده و در عدد کمی از بیماران به انواع بدخیمی‌ها و بیماری‌های عصبی متنه می‌شود. طراحی مدلی برای غربالگری افراد بویژه در مناطق اندمیک می‌تواند به کشف زود هنگام موارد ابتلا و کاهش بار بیماری منجر شود. برای این کار نتایج ۵۹۹ آزمایش شمارش کامل سلول‌های خونی افراد سالم، افراد مبتلا به انواع لوکمی و HTLV-1 مورد بررسی قرار گرفت. مدل‌سازی با استفاده از متدهای CHAID انجام شد. مدل نهایی بر اساس متغیرهای تعداد گلبول‌های سفید، تعداد پلاکتها و درصد اوزینوفیل به صحت ۹۱٪ دست یافت. با اجرای این مدل بر روی نتایج CBC افراد بدون علامت یا بیماران متفرقه در مناطق اندمیک کشور می‌توان افراد ناقل احتمالی را کشف و برای آزمایش‌های تكمیلی معرفی کرد. با توجه به احتمال بروز عوارض متعدد در افراد مبتلا، کشف این موارد می‌تواند به کاهش بار بیماری و ارتقای سطح سلامت افراد به بویژه در مناطق اندمیک منجر شود.

واژه‌های کلیدی: HTLV-I، داده‌کاوی، CHAID، درخت تصمیم (Decision Tree)

مقدمه

ممکن است تظاهرات عصبی و خونی مشاهده شود.^(۳) با توجه به اینکه عوارض این بیماری دیر هنگام ظاهر می‌شود با توجه به نمونه‌های خون می‌توان بررسی‌های بیشتری در این زمینه انجام داد. تشخیص اولیه بیماری در نمونه خون با بهره‌گیری از تست‌های الایزا و تایید تشخیص با کمک تست Western Blot صورت می‌گیرد. شیوع نسبتاً پایین این بیماری در بسیاری از موارد تشخیص آن را به تعویق می‌اندازد و هزینه‌های بسیاری را برای بیمار و نظام سلامت ایجاد می‌کند.

محیط مراقبت سلامت غنی از اطلاعات و ضعیف از دانش است و در سیستم‌های مراقبت سلامت و آزمایشگاه‌های تشخیصی، داده‌های ارزشمندی در دسترس می‌باشد.^(۴) داده‌کاوی از طریق روش‌های مختلف مانند تفسیر تست‌های تشخیصی پیچیده، ترکیب اطلاعات از منابع مختلف (تصاویر، داده‌های بالینی، تصاویر متحرک از نمونه‌ها)، فراهم کردن حمایت‌های لازم برای تشخیص افتراقی و پیش‌آگهی بیمار به پزشکان کمک می‌کند تا روابط پنهان میان داده‌ها و الگوهای مختلف آن پی ببرد.

با توجه به اهمیت و بار بیماری‌های ناشی از عفونت با HTLV-1 و محدودیت‌های موجود در مسیر تشخیص آن، داده‌کاوی داده‌های آزمایشگاهی پایه در مبتلایان به این بیماری می‌تواند نتایج ارزشمندی را برای نظام سلامت کشور فراهم کند. در این مطالعه

HTLV-I^۱ یک رتروویروس است که با انواع مختلفی از بیماری‌ها از جمله بعضی از انواع لنفوم، لوکمی و اختلالات عصبی دیده می‌شود. این ویروس در بعضی از نقاط جهان از جمله جنوب غرب ژاپن اندمیک است. عفونت با این ویروس در ایران نیز در بعضی از نواحی استان خراسان به صورت اندمیک دیده می‌شود.^(۱،۲) عفونت با این ویروس منجر به رشد کلونال لنفوسيت CD4 همراه با تجمع مونوكلونال پرو ویروس HTLV در سلول‌های توموری می‌شود. شایع‌ترین یافته‌های بالینی این بیماری لنفادنوباتی، هپاتوسپلنومگالی، ضایعات پوستی، هیپرکلسیمی و ضایعات لیتیک استخوانی است. از آن جا که این ویروس همانند سایر رتروویروس‌های هم خانواده، لکوسیت‌ها را مورد تهاجم قرار می‌دهد و لکوسیت‌ها هستند که با داشتن اطلاعات ژنتیک ویروس می‌توانند در انتشار و انتقال آلودگی نقش داشته باشند، انتشار HTLV-I بیشتر از طریق فرآورده‌های سلولی خون آماده، سوزن‌های آلوده به ویروس، تماس جنسی و از مادر به فرزند از طریق شیر مادر است.

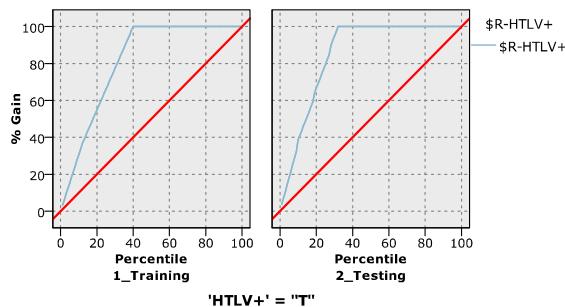
در این بیماری احتمال ابتلای به لوسومی - لنفوم سلول T در بین افرادی که از نظر سرولوژی مثبت هستند حدود یک درصد می‌باشد بنابراین بیشتر افراد آلوده به صورت ناقل باقی می‌مانند. عمدۀ ناقلين HTLV1 بدون علامت هستند و تنها در عده کمی از بیماران

¹The Human T-lymphotropic virus

جدول ۱- میانگین متغیرها در گروههای مختلف و سطح معنی داری تفاوت بین گروههای مختلف بر اساس آنالیز واریانس

	HT LV1	Leuk emia	Hea lthy	P value
WBC(10 000)	13. 7	66.2	8.7	0.6 98
RBC	4.0	3.6	4.6	<0. 001
Hgb	11. 6	9.8	13. 2	<0. 001
MCV	88. 7	89.7	85. 1	0.0 02
MCH	29. 2	42.3	28. 9	0.3 66
MCHC	34. 0	32.9	33. 9	0.7 97
Platelet	178	1009	292	0.2 86
Lymphoc yte	29. 3	27.8	32. 4	0.1 42
Monocyt e	4.7	5.4	6.2	0.5 04
Eosinoph il	3.6	4.8	2.7	0.0 74

مدل سازی با روش CHAID و با $\text{Alpha for Splitting} = 0.05$ و $\text{Alpha for Merging} = 0.05$ پرسون برای متغیر هدف طبقه بندی شده انجام گردید. مراحل تفکیک گروهها یا رشد درخت تصمیم تا رسیدن به زمانی که حداقل یک درصد موارد در شاخه والد باقی بماند ادامه یافت. در مدل نهایی که دارای صحت ۹۱ درصد بود (شکل ۱).



شکل ۱- ارزیابی عملکرد مدل

متغیرهای تعداد گلوبول‌های سفید، تعداد پلاکتها و درصد اوزینوفیل‌ها به کار گرفته شده‌اند و درخت تصمیم نهایی دارای ۴ سطح ($\text{Tree depth} = 4$) بود (شکل ۲).

قصد داریم با داده‌کاوی بر روی نتایج آزمایش کامل خون^۲ مدلی برای پیشنهاد ابتلا به عفونت با این ویروس مطرح کنیم که بتواند در غربالگری مبتلایان و انتخاب موارد محتمل برای انجام آزمایش‌های تكمیلی به کار رود.

روش کار

برای انجام این مطالعه اطلاعات مربوط به نتایج ۵۹۹ مورد آزمایش CBC شامل ۲۴۶ آزمایش از بیماران مبتلا به HTLV1، ۱۴۲ آزمایش از بیماران مبتلا به ALL، ۱۱۰ آزمایش از بیماران مبتلا به ATL و ۱۰۱ آزمایش از افراد سالم جمع‌آوری گردید. این مجموعه آزمایش مربوط به ۱۰۷ نفر بیمار مبتلا به HTLV1 و ۱۰۱ فرد سالم بیمار مبتلا به ALL، ۴۴ بیمار مبتلا به ATL و ۱۰۱ افراد سالم بود. نتایج آزمایش‌های افراد سالم از یکی از آزمایشگاه‌های تشخیص طبی و نتایج آزمایش‌های بیماران از سیستم اطلاعات بیمارستانی بیمارستان‌های قائم و امام رضا(ع) مشهد استخراج شد. داده‌ها از نظر کیفیت مورد بررسی قرار گرفت و موارد خارج از محدوده قابل قبول بازبینی شد.

متغیر هدف در مدل سازی ابتلا به HTLV1 بود. مدل سازی بر روی این داده‌ها با استفاده از متod CHAID و به کمک نرم‌افزار Clementine نسخه ۱۲ انجام شد. روش CHAID که مختصر Chi-squared Automatic Interaction Detector عبارت می‌باشد یکی از انواع درخت تصمیم است که بر پایه (Bonferroni testing) عمل می‌نماید.^(۵)

این داده‌ها با حفظ نسبت میان خوشه‌ها به دو نیمه تقسیم شد و نیمی از داده‌ها برای آموزش و نیمی دوم برای آزمون مدل به کار رفت. مدل طراحی شده بهینه‌سازی شد و از نظر کیفیت با مدل‌های دیگر مقایسه گردید.

یافته‌ها

بانک داده‌های مورد استفاده در این مطالعه محتوی نتایج آزمایش ۳۰۲ CBC ۹۴ نفر شامل بیمار مبتلا به لوکمی، ۱۰۱ فرد نرمال و ۱۰۷ بیمار مبتلا به HTLV1 بود. متغیرهای مورد بررسی شامل تعداد گلوبول‌های سفید، تعداد گلوبول‌های قرمز، هموگلوبین، هماتوکریت، MCHC، MCH و MCV، پلاکت، درصد پلی مورفونوکلئرها، درصد لنفوцит‌ها، درصد مونوسیت‌ها و درصد اوزینوفیل‌ها بود.

نتایج آنالیز اولیه داده‌ها با تکنیک ANOVA و توزیع متغیرهای مذکور در گروههای مختلف در جدول شماره ۱ ذکر شده است.

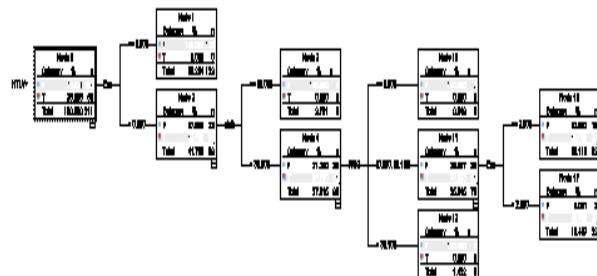
^۲Complete Blood Count



همچنین پیش نهاد می شود با استفاده از داده های بیشتر امکان توسعه روش و کیفیت مدل فراهم شود.

نتیجه گیری

مدل های تصمیم گیری مبتنی بر داده کاوی و به طور خاص تکنیک به کار گرفته شده در این مقاله و درخت تصمیم به دست آمده می توانند در شناسایی بیماران مبتلا به بیماری HTLV1 کمک کننده بوده و به پزشکان و متخصصین در شناسایی سریع تر و آسان تر این افراد کمک نماید.



شکل ۲- مدل نهایی به دست آمده در قالب درخت تصمیم

References

- [1] Boostani, R., Ardakani, A. M., and Ashrafi, H., "Khorasan Disease: Prevalence of HTLV-I Associated Myelopathy/Tropical Spastic Paraparesis (HAM/TSP) In West Azarbaijan from 2004 to 2007," Iranian Red Crescent Medical Journal, vol. 13, pp. 428-430, 2011
- [2] Abbaszadegan, M. R., Gholamin, M., Tabatabaei, A., Farid, R., Houshmand, M., and Abbaszadegan, M., "Prevalence of human T-lymphotropic virus type 1 among blood donors from Mashhad, Iran," Journal of clinical microbiology, vol. 41, p. 2593, 2003.
- [3] Iwanaga, M., Watanabe, T., Utsunomiya, A., Okayama, A., Uchimaru, K., Koh, K. R., Ogata, M., Kikuchi, H., Sagara, Y., and Uozumi, K., "Human T-cell leukemia virus type I (HTLV-1) proviral load and disease progression in asymptomatic HTLV-1 carriers: a nationwide prospective study in Japan," Blood, vol. 116, p. 1211, 2010.
- [4] Jyoti, S., Ujma, A., Dipesh, S., and Sunita, S., "Predictive Data Mining for Medical Diagnosis: An Overview of Heart Disease Prediction," International Journal of Computer Applications, vol. 17, pp. 43-48, 2011.
- [5] Berka, P., Rauch, J., and Zighed, D. A., Data Mining and Medical Knowledge Management: Cases and Applications: Information Science Reference-Imprint of: IGI Publishing, 2009.

بحث

مدل نهایی به دست آمده در این مطالعه دارای صحت ۹۱ درصد در تشخیص افراد مبتلا به HTLV1 بود و این امر تنها با داشتن اطلاعات موجود در یک آزمایش ساده CBC-diff محقق می شود. به این ترتیب این مدل می تواند در شناسایی این بیماران با سهولت به کار گرفته شود و موارد مناسب برای انجام آزمایش های تکمیلی را معرفی کند.

این مدل بر اساس روش CHAID ساخته شده که یکی از انواع روش های مبتنی بر درخت تصمیم می باشد. مزیت کلی این روش در سادگی نمایش کلیه مراحل طبقه بندی و امکان تفسیر روش کار با استخراج قوانین ساده عمل کردی آن است. همین امر بهره گیری از مدل به دست آمده برای کار بر بالین بیمار و حتی در تشخیص سرپایی مراجعین ممکن می سازد.

با اجرای این مدل بر روی نتایج CBC افراد بدون علامت یا بیماران متفرقه در مناطق انديمه کشور می توان افراد ناقل احتمالی را کشف و برای آزمایش های تکمیلی معرفی کرد. با توجه به احتمال بروز انواع بدخیمی ها و اختلالات سیستم اعصاب در افراد مبتلا، کشف این موارد می تواند به کاهش بار بیماری های مذکور و ارتقای سطح سلامت افراد به ویژه در مناطق انديمه منجر شود.