

Evaluation of Most Visited News Websites in Iran Based on Machine Learning

Babak Sohrabi

PhD in Management; Professor in Information Technology Management Group; University of Tehran; Corresponding Author bsohrabi@ut.ac.ir

Amir Manian

PhD in Management; Associate Professor in Information Technology Management Group; University of Tehran; amanian@ut.ac.ir

Moloood Arman

MS in Information Technology Management; University of Tehran arman.moloood@ut.ac.ir

Received: 15, Feb, 2016

Accepted: 26, Apr. 2016

Iranian Journal of
Information
Processing and
Management

Abstract: Success and effectiveness of websites are largely dependent on their quality. The biggest share of the quality of new concept is that technical aspects of products and services combine with customers usage and understanding. Therefore, websites evaluation based on the maximum usage and perception of the customers is considered an important issue to announce to the related organizations. This ranking and evaluation should be performed in a special activity domain so that the first place of website rank determines among its other competitors. In this article achieving the information of websites is automatic and without the intervention of human so that the instant evaluation could be possible. In this study, one of the multi criteria decision-making methods called TOPSIS is used and the weights of the criteria have been achieved on entropy method in the mentioned method. Eventually, according to the Alexa ranking report, 791 ranking news website have been obtained which have most visitors of Iranian users, but on the other hand, just a numerical rank as a final output of websites evaluation can not be very inconsistent with the purpose of competition between websites, so these numerical ranking from TOPSIS method used as output in machine learning method for separating websites from excellent to very poor in six categories as labels for training dataset in classification, instead of using manual labels achieved from experts and users' opinion. For this classification, machine learning techniques, including artificial neural network and support vector machine were used.

Keywords: Websites Evaluation, News Websites, TOPSIS, Automation, Machine Learning, Neural Network, Support Vector Machine

Iranian Research Institute
for Science and Technology

ISSN 2251-8223

eISSN 2251-8231

Indexed in SCOPUS, ISC, & LISTA

Vol. 32 | No. 2 | pp: 551-579

Winter 2017



ارزیابی کیفیت پر مشاهده ترین وبسایت‌های خبری در ایران مبتنی بر روش یادگیری ماشین

باکس سه راهی

دکتری مدیریت؛ استاد؛ دانشگاه تهران؛

گروه مدیریت فناوری اطلاعات؛

bsohrabi@ut.ac.ir پدیدآور رابط

امیر مانیان

دکتری مدیریت؛ دانشیار؛ دانشگاه تهران؛

گروه مدیریت فناوری اطلاعات amanian@ut.ac.ir

مولود آرمان

کارشناسی ارشد مدیریت فناوری اطلاعات؛

دانشگاه تهران arman.molood@ut.ac.ir

دریافت: ۱۳۹۴/۱۱/۲۶ | پذیرش: ۱۳۹۵/۰۲/۰۷



فصلنامه | علمی پژوهشی

پژوهشگاه علوم و فناوری اطلاعات ایران

شما (آجایی) ۲۲۱۱-۸۲۲۳

شما (الکترونیکی) ۲۲۵۱-۸۲۳۱

SCOPUS، ISC، LSTA، jipm.irandoc.ac.ir

دوره ۳۲ | شماره ۲ | صص ۵۰۱-۵۷۹

زمستان ۱۳۹۵



چکیده: موقفيت و کارابي وبسایت‌ها تا حد زیادی وابسته به کيفيت آن هاست. بزرگ‌ترین سهم از مفهوم جدید کيفيت اين است که جنبه‌های فني محصولات و سرويس‌ها با استفاده و برداشت مشتريان ترکيب می‌شود. بنابراین، ارزیابی وبسایت‌ها بر اساس بيشترین استفاده و درک از سمت مشتريان امر مهمی بهشمار می‌آيد تا موقفيت يك وبسایت را به سازمان‌های مربوطه اعلام کند. اين رتبه‌بندی و ارزیابی بايستی در يك دامنه خاص، فعالیتی صورت گيرد، تا رتبه وبسایت در برابر رقبايان آن تعیین گردد. اين پژوهش بر آن است که بتوان ارزیابی وبسایت‌ها را با به دست آوردن اطلاعات آن‌ها به صورت خودکار و بدون دخالت نیروي انساني، به صورت لحظه‌ای و بلاذرنگ ممکن ساخت. برای اين منظور از دو روش یادگیری ماشین، شبکه عصبی و ماشین بردار پشتيبان استفاده شده است. از آنجا که از الگوريتم یادگیری با نظارت در اين روش‌ها استفاده کرده‌ایم، نياز به داده‌های برچسب‌دار وجود داشت که به جای برچسب‌دار کردن خروجي‌ها توسيط خبرگان و به صورت دستي از يكى از روش‌های تصميم گيری چندمعياره (MCDM) به نام «تاپسيس» كمک گرفته شده است. در اين روش وزن‌های معياره‌ای ارزیابی با استفاده از روش آنتروپي به صورت خودکار محاسبه گردیده است. در نهايىت، رتبه‌بندی ۷۹۱ وبسایت خبری که بر اساس گزارش «الکسا» بيشترین بازدید‌كتنده از طرف کاربران ايراني را داشته‌اند، با روش «تاپسيس» حاصل شد، ولی از سمت ديگر ارائه يك

رتبهٔ عددی به عنوان خروجی نهایی ارزیابی وبسایت‌ها چندان با هدف رقابت آن‌ها هم‌خوانی ندارد. به همین خاطر، از این رتبه‌های عددی به عنوان خروجی روش‌های یادگیری ماشین به جای رتبه‌بندی خبرگان و افراد استفاده گردید تا بتوان وبسایت‌ها را در شش طبقهٔ جداگانه، از بسیار عالی تا بسیار ضعیف، برچسب‌دار نمود. در ادامه، از روش‌های یادگیری ماشین ذکر شدهٔ جهت طبقه‌بندی و همچنین، پیش‌بینی طبقهٔ یک وبسایت جدید استفاده شده است. در نهایت، این پژوهش به این نتیجه رسید که امکان طراحی سیستمی با دقت بالا برای ارزیابی وبسایت‌های خبری با روش شبکهٔ عصبی و ماشین بردار پشتیبان وجود دارد، به گونه‌ای که این سیستم از عوامل مهم تأثیرگذار بر کیفیت وبسایت‌های خبری تشکیل شده و به صورت خودکار قابلیت جمع‌آوری اطلاعات آن‌ها وجود داشته باشد.

کلیدواژه‌ها: ارزیابی وبسایت، وبسایت‌های خبری، روش تاپسیس (TOPSIS)، خودکارسازی، یادگیری ماشین

۱. مقدمه

در سال ۲۰۱۵ بر اساس آمار «استاتستیا»^۱ تعداد کاربران اینترنتی فراتر از ۳ بیلیون نفر بوده و تعداد وبسایت‌ها به صورت روزافزونی در حال رشد و افزایش هستند. مهم‌ترین هدف هر وبسایت ارائهٔ اطلاعات است. وبسایت‌ها انواع مختلفی دارند، ولی اغلب آن‌ها منابع غنی از اطلاعات بوده و با کمترین هزینه، به سرعت و به سادگی می‌توانند در فضای جهانی وب، بر روی اینترنت منتشر گردند. بنابراین، در سرتاسر جهان شاهد آن هستیم که با رشد سرعت تغییرات، پویایی محیط، و افزایش رقباً تقریباً هر نوعی از کسب و کار برای بهره‌برداری از مزایای اینترنت به سمت آن رفه است.

بانگاهی به پر مشاهده‌ترین وبسایت‌ها در آمار وبسایت معتبر «الکسا»، بیشترین تکرار در بین صد سایت برتر، هم در جهان و هم در ایران، متعلق به سایت‌های خبری است. از آنجا که رتبه‌بندی وبسایت «الکسا» بر اساس تعداد بازدید کاربران وبسایت‌ها صورت می‌گیرد، می‌توان به این نکته رسید که این نوع وبسایت‌ها از دید عموم به شدت مورد استقبال واقع شده و توانسته‌اند جایگاه خوبی در میان مردم داشته باشند. بسیاری از نهادها و سازمان‌های خبری در ایران به دنبال درک میزان عمومیت و استقبال میان مخاطبان اخبار آنلاین هستند و بسیار علاقه مندند که جایگاه خود را پیوسته نسبت به سایر رقبای خود ارزیابی نمایند. امروزه، این موضوع برای ارزیابی جایگاه وبسایت‌های کسب و کاری مشخص تبدیل به یکی از موارد تجاری برای شرکت‌های فعال در حوزهٔ وب گردیده است.

1. Statistica

از این رو، لزوم شناخت مهم‌ترین عوامل و ویژگی‌های تأثیرگذار بر نوع خاصی از وب‌سایت‌ها، جزء ابتدایی ترین و در عین حال، مهم‌ترین اقداماتی است که برای ارزیابی وب‌سایت‌ها باید صورت گیرد. همچنین، مدل‌سازی کمی این ویژگی‌ها با تعیین اهمیت و وزنی که هر کدام از آن‌ها در کیفیت یک وب‌سایت دارند، به نهادهای ذی‌ربط و مالکان وب‌سایت‌ها کمک خواهد کرد که ابتدا بر اساس اولویت و اهمیت مشخص شده، وجود متفاوت وب‌سایت خود را در نظر گرفته و برای بهتر کردن جایگاه خود در میان رقبا، در جهت برطرف کردن مشکلات و کمبودهای آن اقدام نمایند. بعد از شناسایی این معیارها، می‌توان در راستای امکان طراحی سیستمی برای ارزیابی کیفیت وب‌سایت‌ها اقدام نمود.

دو پرسش اصلی که این پژوهش به دنبال یافتن پاسخی برای آن‌هاست، در زیر بیان شده است:

۱. مهم‌ترین عواملی که در ارزیابی خودکار کیفیت وب‌سایت‌های خبری می‌توانند دخیل باشند، چیست؟

۲. آیا می‌توان سیستمی خودکار برای ارزیابی کیفیت وب‌سایت‌های خبری طراحی نمود؟

در ادامه، ابتدا معرفی بر ادبیات موضوع داشته و سپس، با بیان روش پژوهش، بر اساس مدل رائده شده شاخص‌ها و نمونه‌ای از اطلاعات کمی، که به صورت خودکار جمع‌آوری شده‌اند، مطرح می‌شود و با طراحی چند سیستم مختلف، خروجی آن‌ها در بخش یافته‌های پژوهش با یکدیگر مقایسه شده و در نهایت، به بیان نتایج و پیشنهادات پرداخته می‌شود.

۲. معرفی بر ادبیات موضوع

اینکه یک وب‌سایت تا چه حد باید پاسخگوی انتظارات کاربران و مشتریان باشد، پرسش مهمی است که با کیفیت وب‌سایت ارتباط پیدا می‌کند (زاهدی ۱۳۸۹). از آنجا که تنوع وب‌سایت‌های موجود بسیار زیاد است و ابعاد کیفیت خدمات بر اساس نوع وب‌سایت‌ها با یکدیگر متفاوت هستند، بنابراین، یکی از بهترین شیوه‌های تعریف کیفیت با درنظر گرفتن نوع وب‌سایت است.

کیفیت، مجموعه‌ای از ویژگی‌ها و مشخصات محصول یا خدمت است که بتواند نیازهای صریح یا ضمنی را برآورده کند (کی. هو، ۱۳۷۹). این نیازها اغلب با توجه به نظر کاربران و مشتریان و برآوردن خواسته‌های آنان درآمیخته است و برخی اعتقاد دارند که جلب رضایت مشتریان و برآوردن خواسته‌های آنان مهم‌ترین عامل کیفیت می‌باشد (زاهدی، ۱۳۸۹). از سوی دیگر، از دیگر سرعت تکامل فناوری‌های وب، منجر به کاهش چرخه عمر وب‌سایت‌ها گردیده و

از آنجاکه پژوهش‌های کیفی به شدت زمان بر هستند، دیگر زمان چندانی برای پژوهش‌های کیفی و ارتباط مستقیم با کاربران و مشتریان برای ارزیابی کیفی وب‌سایت‌ها باقی نمی‌ماند. علاوه بر این، هر کاربر با توجه به نیاز خود معیارهای متفاوتی برای کیفیت وب‌سایت‌ها داشته و حتی با تغییر زمان، ارزیابی مجدد برای دسته‌ای ثابت از وب‌سایت‌ها نتیجه‌ای متفاوت خواهد داشت (Li and Yamada 2009). در چنین شرایطی در مورد پژوهش‌های کیفی در باره ارزیابی وب‌سایت‌ها به تعارض بر می‌خوریم و در این جاست که اهمیت ابزارها و سازوکارهای ارزیابی کیفیت وب‌سایت‌ها معلوم می‌شود.

یکی از مهم‌ترین موضوعاتی که امروزه جزء دغدغه‌های عمده مدیران و بهره‌برداران سایت‌های وب شده، موضوع ارزیابی وب‌سایت‌هاست (پاشازاده و حاجی‌زین‌العابدینی ۱۳۸۸). روش‌های متفاوت زیادی توسط محققان برای ارزیابی وب‌سایت‌ها پیشنهاد شده است، ولی هنوز تحقیقات بر روی آن‌ها ادامه دارد (ولریچ و دیگران، ۲۰۱۱). در واقع، مفهوم ارزیابی وب‌سایت اغلب با مفهوم ارزیابی وب در ادبیات تحقیق اشتباہ گرفته می‌شود. این امر، بسیار مهم است که دامنه و هدف ارزیابی معلوم گردد: آیا مطالعه بر روی ارزیابی وب است یا ارزیابی وب‌سایت‌هایی از نوع خاص؟ بنابراین، آیا هدف از ارزیابی، طراحی مجدد وب‌سایت است یا رتبه‌بندی وب‌سایت‌ها یا به دست آوردن آماری از ویژگی‌های آن‌ها؟ در نتیجه، به تمرکزی متفاوت برای روش ارزیابی، بر اساس هدف و پلاتفرم ارزیابی نیاز می‌باشد (Zahran et al. 2014).

علی‌رغم افزایش چشمگیر وب‌سایت‌ها و کاربران اینترنتی آن‌ها، تعداد مقالات آکادمیک، که به تحقیق در وجود و ویژگی‌های مختلف وب‌سایت‌ها پرداخته باشند، محدود است (Hernandez, Jimenex and Martin 2009) (Younghwa and Serhat and Cengiz 2012). در رابطه با عوامل تأثیرگذار بر کیفیت وب‌سایت‌ها و روش‌های ارزیابی آن‌ها، پژوهش‌هایی بر روی وب‌سایت‌های تجارت الکترونیک، وب‌سایت‌های کتابخانه‌ای و دانشگاهی صورت گرفته است (Hsiu-Fen 2010; Kenneth 2006; Hernandez, Jimenex and Martin 2009). ولی، تا کنون در باره معیارهای ارزیابی خاص وب‌سایت‌های خبری، بهخصوص با توجه به درنظرگرفتن روش ارزیابی خودکار، بهندرت پژوهشی انجام گرفته است (کنلوپلوس و کتسیانتیس، ۲۰۱۲). در پژوهش «کنلوپلوس» هم تمرکز اصلی بر ارزیابی وب‌سایت‌های خبری یونانی نیست، بلکه گرایش بیشتر به سمت طراحی سیستمی توصیه گر برای تطابق اخبار با پروفایل کاربران است. وی در ابتدا بر اساس ویژگی‌هایی، که اغلب آن‌ها را از سایت «الکسا» استخراج کرده، وب‌سایت‌های خبری یونان را ارزیابی می‌کند.

ابزارهای ارزیابی خودکار و وب‌سایت‌ها نقش بزرگ‌تر و تأثیرگذارتری را به نسبت ابزارهای ارزیابی غیر خودکار و وب‌سایت‌ها در رتبه‌دهی و ارزیابی آن‌ها بازی می‌کنند (Dominic et al.

(2011). علاوه بر این، در تعریف خودکاربودن ارزیابی، اصولاً دیدگاه نویسنده‌گان فقط به سمت استفاده از ابزارهای آنلاین ارزیابی خودکار وب‌سایت‌ها، مانند استفاده از ابزار وب‌اگرکت^۱ (حسن‌زاده و نویدی، ۱۳۸۹)، سرویس اعتبارسنجی W3C HTML (Bauer and Scharl 2000) یا ابزار اندازه‌گیری میزان عمومیت جهانی وب‌سایت (Fang 2007; Cho and Adams 2005) Scowen 2007؛ (Scowen 2007؛ Fang 2007؛ Cho and Adams 2005) یا بوده است. پژوهش‌های انگشت شماری در رابطه با ارزیابی خودکار وب‌سایت‌ها صورت گرفته که تأثیر اغلب معیارها و ویژگی‌های تأثیرگذار بر وب‌سایت‌ها را در نظر داشته‌اند (Li and Yamada 2009).

یکی از موضوعات مهم در زمینه توسعه سیستم‌های اطلاعاتی، یادگیری ماشین است. برای پیش‌بینی موفقیت کسب و کار وب‌سایت‌ها مقالات و پژوهش‌هایی ارائه شده است، ولی غیر از مبحث روش‌های یادگیری برای رتبه‌دهی که مبنی بر روش‌های یادگیری ماشین هستند و بهروش‌های مبنی بر ارتباط نیز معروف‌اند (Derhami et al. 2013) و از مهم‌ترین ویژگی‌های آن نیاز به دسترسی به شبکه ارتباطات وب‌سایت‌ها برای تعیین رتبه می‌باشد، تقریباً از دیگر روش‌های یادگیری ماشین برای مسائل مرتبط با وب‌سایت‌ها، خصوصاً ارزیابی آن‌ها، بهندرت استفاده شده است (Zhang et al. 2014; Li and Yamada 2009).

۳. روش پژوهش

در پژوهش حاضر برای تجزیه و تحلیل داده‌های گردآوری شده در بخش کمی، از روش‌های آماری و روش‌های یادگیری ماشین استفاده شده است. همان‌گونه که واضح و مشخص است، با گذشت زمان علم نیز پیشرفت می‌کند. در پی کشف محدودیت‌های روش‌های قدیمی روش‌های جدید علمی ایجاد می‌شود و از آنجا که روش‌های آماری جزء روش‌های قدیمی داده کاوی محسوب می‌شوند، از این قاعدة کلی مستثنی نیستند. داشتن فرض اولیه در مورد داده‌ها یکی از این موارد است.

در جایی پایه و اساس داده کاوی به دو مقوله آمار و هوش مصنوعی تقسیم شده است که روش‌های مصنوعی به عنوان روش‌های یادگیری ماشین در نظر گرفته می‌شوند. فرق اساسی بین روش‌های آماری و روش‌های یادگیری ماشین بر اساس فرض‌ها و یا طبیعت داده‌هایی است که پردازش می‌شوند. به عنوان یک قانون کلی، فرض‌های روش‌های آماری بر این اساس است که توزیع داده‌ها مشخص است و در بیشتر موارد فرض بر این است که توزیع، نرمال است و در

1. webxact

نهایت، درستی یا نادرستی نتایج نهایی به درست بودن فرض اولیه وابسته است. در مقابل، روش‌های یادگیری ماشین از هیچ فرض در مورد داده‌ها استفاده نمی‌کنند و همین مورد باعث تفاوت‌هایی بین این دو روش است.

در این پژوهش از روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی به عنوان روش یادگیری ماشین و روش «تاپسیس»^۱ از روش‌های تصمیم‌گیری چندمعیاره برای داوری در باره رتبه‌های مجموعه داده فراهم شده است.

- مراحل طراحی و اجرای سیستم یادگیری که در این پژوهش به کار رفته، به شرح زیر است:
۱. انتخاب شاخص‌های مهم ارزیابی کیفیت وب‌سایت؛
 ۲. جمع‌آوری مجموعه داده؛
 ۳. رتبه‌دهی بر اساس روش «تاپسیس»؛
 ۴. تعیین روش یادگیری ماشین؛
 - ۱-۴. پیش‌پردازش داده‌ها؛
 - ۲-۴. تقسیم داده‌ها؛
 - ۵-۴. انتخاب الگوریتم یادگیری؛
 - ۶-۴. تعیین پارامترهای مورد نیاز ماشین یادگیری؛
 - ۷-۴. آزمایش داده‌ها؛
 - ۸-۴. آزمون داده‌ها.

در ادامه به توضیح هر یک از مراحل پرداخته شده است.

موارد شناسایی شده از تحقیقات پیشین با درنظر گرفتن نوع استفاده از این معیارها در ارزیابی خودکار استخراج گردیدند و در نهایت، ۱۳ شاخص اصلی برای سنجش حاصل گردید. لیستی از مهم‌ترین عوامل تاثیرگذار در کیفیت وب‌سایت‌ها در زیر ارائه گردیده است:

- ◊ همگانی بودن وب‌سایت که با شاخص رتبه صفحه گوگل، تعداد کاربر مشاهده کننده وب‌سایت، و تعداد صفحات مشاهده شده همان کاربر و میزان دلتای تغییرات تعداد کاربران در سه ماه گذشته سنجیده می‌شود.
- ◊ دسترسی‌پذیری وب‌سایت که با شاخص امتیاز موتور جست‌وجو، میزان نمایه شدن در موتورهای جست‌وجوی مختلف، و جایگاه وب‌سایت در خروجی query «وب‌سایت‌های خبری» در موتور جست‌وجوی گوگل سنجیده می‌شود.

1. Topsis

۳-۱. انتخاب شاخص‌های مهم ارزیابی کیفیت وب‌سایت

با توجه به اینکه ادبیات پژوهشی ارزیابی کیفیت وب‌سایت‌ها از غنای بالایی برخوردار است، از این رو، برای استخراج شاخص‌ها از روش‌های هدایت‌شده تلخیصی به صورت ترکیبی استفاده شده است. مهم‌ترین فرض در تحلیل محتوا عبارت است از شناسایی واژگانی که بیشترین میزان تکرار و فراوانی را در متون علمی دارند. میزان دفعات تکرار این واژگان در متون مختلف علمی، نشان‌گر میزان اهمیت و توجه پژوهشگران مختلف به آن شاخص‌هاست. در حقیقت، مهم‌ترین گام تحلیل محتوا را می‌توان محاسبه فراوانی عبارات و شاخص‌های مد نظر پژوهشگر در محتوای علمی در نظر گرفت. تحلیل محتوا قادر است با هر داده‌ای از قبیل داده‌های حاصل از سخنرانی، مقاله، کتاب، تصویر، مصاحبه، و مجله ارتباط برقرار کند (Reesi vananie, Manian and Shafia 2013).

مهم‌ترین روش‌های گردآوری اطلاعات در این قسمت از پژوهش، استفاده از روش‌های کتابخانه‌ای است که به صورت گسترده از مطالعه کتابخانه‌ای شامل کتب و مقالات فارسی و لاتین، پایان‌نامه‌های داخلی و خارجی، تحقیقات و گزارشات معتبر و مرتبط و همچنین، اینترنت جهت گردآوری مفاهیم علمی و تحلیل محتوای ادبیات موضوعی و شاخص‌های سنجش استفاده خواهد شد.

بخش کیفی این پژوهش از سؤال اول نشأت می‌گیرد، که فرایند شناخت مهم‌ترین عوامل کیفیت وب‌سایت‌ها را فراهم می‌کند، البته با تأکید بر این موضوع که این عوامل امکان استفاده در فرایند گردآوری و ارزیابی خودکار را داشته باشند. بعد از تمامی مطالعات منطبق با موضوعات مطرح در ارزیابی کیفیت وب‌سایت، مهم‌ترین عوامل برای ارزیابی خودکار کیفیت وب‌سایت‌ها شناخته شد. همان‌طور که پیش‌تر هم بیان شد، یکی از روش‌های تحلیل محتوا زمانی که تحقیقات زیادی در ارتباط با موضوع صورت گرفته باشد، بررسی تحقیقات و مطالعات پیشین است تا در نهایت، به اشباع رسیده و حرف تازه‌ای در تحقیقات دیده نشود. موارد شناسایی شده از تحقیقات پیشین با درنظر گرفتن نوع استفاده از این معیارها در ارزیابی خودکار استخراج گردیدند و در نهایت، ۱۳ شاخص اصلی برای سنجش حاصل گردید. لیستی از مهم‌ترین عوامل تأثیرگذار در کیفیت وب‌سایت‌ها در زیر ارائه گردیده است:

- ◊ همگانی بودن وب‌سایت که با شاخص رتبه صفحه گوگل، تعداد کاربر مشاهده کننده وب‌سایت، و تعداد صفحات مشاهده شده همان کاربر و میزان دلتای تغییرات تعداد کاربران در سه ماه گذشته سنجیده می‌شود؛
- ◊ دسترس پذیری وب‌سایت که با شاخص امتیاز موتور جست‌وجو، میزان نمایه شدن در موتورهای جست‌وجوی مختلف، و جایگاه وب‌سایت در خروجی query «وب‌سایت‌های

- خبری» در موتور جستجوی گوگل سنجیده می‌شود؛
 - ◇ سرعت که با شاخص میانگین زمان بارگذاری سنجیده می‌شود؛
 - ◇ پیمايش که با شاخص تعداد کل لینک‌هایی که به سایت داده شده، محاسبه می‌شود؛
 - ◇ نحوه نمایش که با میزان خطای موجود در قالب کد HTML سایت که از وبسایت W3C کسب گردیده، سنجیده می‌شود؛
 - ◇ محتوای چندرسانه‌ای که با میانگین تعداد فایل‌های تصویری، فلاش، ویدئو و صدا در صفحه اصلی وبسایت سنجیده می‌شود؛
 - ◇ سابقه وبسایت که با شاخص میزان عمر دامنه سنجیده می‌شود؛
 - ◇ ضریبی از ارزیابی‌های مورد قبول جهانی که در اینجا رتبه ترافیک سایت «الکسا» در نظر گرفته شده که بر اساس میزان مشاهده کاربران وبسایت‌ها رتبه‌بندی می‌شوند.
- نمایی از این عوامل را در شکل ۱ می‌توان مشاهده نمود.



شکل ۱. عوامل مؤثر در کیفیت وبسایت

۲-۳. جمع‌آوری مجموعه داده

روش‌های غیر کتابخانه‌ای (استفاده از خزشگر): برای جمع‌آوری اطلاعات و وب‌سایت‌ها و اطلاعات تاریخچه‌ای آن‌ها، در این پژوهش از روش‌های مبتنی بر خزش استفاده می‌شود. فرایند خزش دو نوع است: نوع اول، خزش و جمع‌آوری تمام داده‌ها از یک سرویس خاص، مانند کاری که موتورهای جست وجو انجام می‌دهند؛ نوع دوم، خزش هدفمند. در این روش بسته به اطلاعات مورد نیاز، روبات مورد نظر طراحی شده و در سرویس‌های مختلف به خزش و جمع‌آوری اطلاعات می‌پردازد. استفاده از نوع اول خزش در تحلیل و ارزیابی بسیار سودمند بوده، ولی دارای هزینه نگهداری بسیار بالایی است. از نوع دوم خزش نیز بیشتر برای پرکردن خلاهای اطلاعاتی و کسب اطلاعاتی خاص استفاده می‌شود. خزش، بسته به نوع آن دارای الگوریتم‌های مختلف بوده و بایستی برای هر مورد و هر پایگاه داده‌ای به صورتی جداگانه طراحی شود. اطلاعات شاخص‌های شناسایی شده با کمک خزشگرها از منابع اطلاعاتی موجود در جدول ۱ استخراج گردیده است. این اطلاعات مرتبط با ۱۳ شاخص برای ۷۹۱ وب‌سایت خبری، که بر اساس آمار «الکسا» بیشترین بازدید در ایران را داشتند، جمع‌آوری گردیده است.

جدول ۱. منابع جمع‌آوری اطلاعات

نام شاخص	منبع گردآوری اطلاعات
رتبه ترافیک الکسا	سایت الکسا
رتبه صفحه گوگل	سایت گوگل
امتیاز موتور جست وجو	سایت استاتس کراپ
تعداد لینک Backward	سایت استاتس کراپ / سایت الکسا
تعداد کاربران منحصر به فرد	سایت الکسا
میزان نرخ تغییر تعداد کاربران منحصر به فرد	سایت الکسا
میزان مشاهدات وب‌سایت	سایت الکسا
محتوای مالتی مدیا	خود و وب‌سایت
عمر دامنه	سایت الکسا / سایت استاتس کراپ
سرعت بارگذاری صفحه	سایت الکسا / سایت استاتس کراپ
جایگاه وب‌سایت در جست وجوی گوگل	سایت گوگل
میانگین تعداد نمایه در موتورهای جست وجو	سایت گوگل / سایت ینگ / سایت یاهو
میزان خطای کد HTML	W3C

۳-۳. رتبه‌هی بر اساس روش «تاپسیس»

بعد از جمع آوری اطلاعات شاخص‌ها، داده‌ها را نرمالایز کرده و وزن شاخص‌ها به روش آنتروپی اطلاعات به دست آمد. این وزن‌ها در جدول ۲ آورده شده است. بر اساس مقادیر شاخص و این اوزان، میزان فاصله نسبی از ایده‌آل مثبت برای هر وب‌سایت اندازه گیری شده است و در نهایت، اطلاعات ۳۰ سایت برتر رتبه‌داده شده به وب‌سایت‌های خبری در جدول ۳ آورده شده است.

جدول ۲. وزن معیارها با استفاده از روش آنتروپی

نام شاخص	وزن شاخص از روش آنتروپی
رتبه صفحه گوگل	۰,۱۴۶۵۷۸
اعتیاز موتور جست و جو	۰,۰۶۴۶۹۲
رتبه تراویک اکسا	۰,۲۵۸۹۱۵
عمود اندی	۰,۱۷۰۵۹۳
میاگیکن تعداد نمایه در موتورهای جست و جو	۰,۱۷۰۵۹
backward لینک‌های	۰,۰۲۸۸۹۱
HTML خطای در کد	۰,۱۳۶۷۴
تعداد کاربر مخصوص به فرد	۰,۱۱۹۱۲
میزان تغییر امت در تعداد کاربر	۰,۰۰۵۸۴۴
میزان مشاهده صفحات	۰,۰۴۳۱۹۴
زمان بارگذاری صفحات	۰,۰۳۱۳۱۴
جایگاه وب‌سایت در جست و جو گوگل	۰,۱۳۷۴۸۵
محتواهی چندین‌ساله‌ای	۰,۰۸۲۲۹

پژوهشگاه علوم انسانی و مطالعات فرهنگی

رئال جامع علم انسانی

وزن شاخص از روش آنتروپی

جایگاه وب‌سایت در جست و جو گوگل	۰,۱۳۷۴۸۵
محتواهی چندین‌ساله‌ای	۰,۰۸۲۲۹
زمان بارگذاری صفحات	۰,۰۳۱۳۱۴
میزان مشاهده صفحات	۰,۰۴۳۱۹۴
تعداد کاربر مخصوص به فرد	۰,۱۱۹۱۲
backward لینک‌های	۰,۰۲۸۸۹۱
HTML خطای در کد	۰,۱۳۶۷۴
میزان تغییر امت در تعداد کاربر	۰,۰۰۵۸۴۴
میزان مشاهده صفحات	۰,۰۴۳۱۹۴
جایگاه وب‌سایت در جست و جو گوگل	۰,۱۳۷۴۸۵

جدول ۳. داده‌های خام و نتایج نهایی ۳۰ سایت برتر خبری بر اساس روش «تاپسیس»

ردیه	نام و وبسایت	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱
ردیه صفحه گوگل	Cnn.com	۹	۹	۸	۵	۵	۷	۳	۱	۱	۱	۱
امتیاز متور جستجو	Reuters.com	۵۰	۹۰	۹۳	۵۷	۵۷	۷۹	۴۲	۵۷	۸۹۲۵	۸۹۲۵	۸۹۲۵
ردیه تو افیک اکسا	Cnet.com	۱۸۰۱	۳۱۵۷	۴۷۷	۸۰	۲۷۷	۶۸	۰	۰	۰	۰	۰
عمر (ماه) (۵۰)	Ghatreh.com	۲۴۳۶,۴۵۲۱	۲۴۷۶,۱۳۴۲	۲۳۸۰,۹۰۳	۸۶,۹۳۰,۱۴	۹۵,۴۷۵۳۴	۰	۰	۰	۰	۰	۰
میانگین تعداد نمایه در متورهای جستجو	Ruvr.ru	۴۳۶۹۰۰۰	۴۰۰۰۲۸	۷۸۵۰۰۰	۲۱۴۳۵۲	۱۱۱,۹۴۷	۱۰,۸۸۶۸۱	۸۸۳۳۵۰۳,۷	۰	۰	۰	۰
خطا در کد HTML	Vista.ir	۳۷۵	۲۵۲	۹	۲۵۱	۷۰۹	۰	۰	۰	۰	۰	۰
لینک‌های backward	SkySports.com	۲۶۰۴۷۶	۱۴۹۷۶۸	۱۷۰۴۰۲	۲۹۶۶	۱۱۹۴۸۹	۱۰,۱۵۸	۰	۰	۰	۰	۰
تعداد کاربر مختص به فرد	۱۸۷۷۰	۴۱۱۰	۱۳۷۸۱	۳۵۸	۵۶۰	۳۹۲	۰	۰	۰	۰	۰	۰
میزان تغییرات در تعداد کاربر	۰,۹	۴,۹۵	۱,۰۹	۰,۵	۰,۵	۱۹,۵	۰	۰	۰	۰	۰	۰
میزان مشاهده صفحات	۳,۱۹	۲,۳۴	۲,۹۵	۳,۸۶	۲,۹۲	۳,۷۳	۰	۰	۰	۰	۰	۰
زمان بارگذاری صفحات (ثانیه)	۲۶۳۷	۳۰۰۷	۳۱۵۱	۲۰۰	۲۵۸۷	۱۳۵۷	۰	۰	۰	۰	۰	۰
جایگاه و وبسایت در جستجو گوگل	-	-	-	۷۹	-	۱۹۹	-	-	-	-	-	-
نمودن ایجاد سایه ای	۲۹,۳۵	۸,۵	۱۲,۵	۲,۷۵	۱۷,۵	۴,۰	۱۱,۲۵	۰	۰	۰	۰	۰
میزان فاصله از ایده آل +	۷۵۸۰,۰۳۰	۶۹۴۵,۹۹۴	۲۵۷۹۸,۵۲	۳۷۹۸۱,۱۷	۵۴۳۴۶,۱۸	۵۴۳۴۷,۱۸	۵۵۹۱۶,۲۰	۰	۰	۰	۰	۰
میزان فاصله از ایده آل -	۷۵۶۶۶,۱۱	۶۸۳۵۰,۳۳	۴۸۸۵۷,۷	۳۶۸۱۸,۴۹	۲۰۴۷۳,۹۵	۱۹,۷۱,۹	۱۵۲۲۱,۸۴	۰	۰	۰	۰	۰
نرودی نسبی به راه حل ایده آل همیلت	۰,۹۰۱۰,۰۶۳	۰,۹۰۰۸,۶۱۷	۰,۹۰۰۷,۶۱۸	۰,۷۳۵۶۸	۰,۷۳۵۶۱	۰,۷۳۵۶۸	۰,۷۳۵۶۸	۰,۷۳۵۶۸	۰,۷۳۵۶۸	۰,۷۳۵۶۸	۰,۷۳۵۶۸	۰,۷۳۵۶۸

ردیف	نام وبسایت	ردیف صفحه گوگل	ردیف صفحه جستجو	ردیف صفحه موتور جستجو	ردیف صفحه انتشار	ردیف صفحه اتفاق اکسا	ردیف صفحه اخبار				
۱	Khabarfarsi.com	۴	۵	۴	۵	۲	۸	۶	۶	۶	۶
۲	Khorasannews.com	۳۱	۵۸	۴۷	۴۲	۴۹	۹۳	۷۲	۷۲	۷۲	۷۲
۳	Jamnews.com	۳۴	۳۰۴	۵۶	۷۹	۱۸۹۰	۱۱۷۷۲	۴۲	۴۲	۴۲	۴۲
۴	Jahannnews.com	۷۲,۱۴۹۳۸	۱۴۰,۷۷۸۵۳	۴۸,۰۱۶,۳	۴۰,۶۱۱۴	۸۱,۰۴۱	۱۱۷۷۲	۱۳۳,۹۵۹۷	۱۳۳,۹۵۹۷	۱۳۳,۹۵۹۷	۱۳۳,۹۵۹۷
۵	Eeqep.ir	۲۶۹	۴۲۱۸	۲۸۷۳	۵۱۵۹	۹۷	۱۱	۳۱	۱۰۳	۱۰۳	۱۰۳
۶	Cbc.ca	۵۷۶	۴۲۱۸	۴۰۳	۴۷۷۲	۱۵۲	۶۳۷۱۰	۱۳۸۴	۱۳۸۴	۱۳۸۴	۱۳۸۴
۷	Mehnews.com	۸,۹۲-	۸,۹۲-	۸,۹۲-	۱۰,۹۰-	۱۹,۹	۱۴۵۷	۶۹۰	۶۹۰	۶۹۰	۶۹۰
۸		۴,۳۸	۴,۳۸	۴,۷۱	۴,۲۱	۱,۷۶	۲,۳۱	۳,۶۸	۳,۶۸	۳,۶۸	۳,۶۸
۹		۱۷۸۹	۱۷۸۸	۲۱۹۴	۲۰۵۰	۱۶۱۱	۲۹۸۵	۱۶۴۵	۱۶۴۵	۱۶۴۵	۱۶۴۵
۱۰		۱	۱۱۸	۲۷۷	۲۱	-	-	۵۸۱	۵۸۱	۵۸۱	۵۸۱
۱۱											
۱۲											
۱۳											
۱۴											

زودیکی نسبی به راه حل اینده آل همیلت

+ میزان فاصله از اینده آل +
- میزان فاصله از اینده آل -

۷۲,۱۴۹۳۸,۷۷۸۵۳

۴۸,۰۱۶,۳

۴۰,۶۱۱۴

۳۹۹,۷۷۳

۴۰,۳۷۵۲,۳

۴۲,۰۱۴

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

۳۲۵,۲۲۳

ردیه	نام و وبسایت	Youm7.com	Tabnak.ir	Irna.ir	Forexfactory.com	Afkamews.com	Aljazeera.com	Asriran.com
ردیه صفحه گوگل		۹	۵	۷	۴	۶	۸	۹
امتیاز متور جستجو		۵۲	۵۰	۵۵	۵۰	۵۲	۵۷	۴۳
امتیاز ترافیک اکسا		۱۱۶۴۶	۱۲	۱۱	۴۵۷۸	۴۰	۴۷۶۱	۲۵
عمرو (۱۵۰۰۰)		۷۳,۹۸۶۳	-	-	۱۱۸,۴۲۱۹	۲۰۰,۱۷۵۳	۹۴,۲۹۰۴۱	-
میانگین تعداد نمایه در موثرهای جستجو		۳۹۶۰,۱۳۵	۳۱۵۶۶۹,۷	۳۱۹۳۷۴	۳۴۶۶۹۴,۷	۳۰۰۳۵۷	۳۳۰,۱۳۳	۲۷۱۹۴,۳
خطای در کد HTML		۹۷۶	۱۲	۵۵	-	۳۰۰	-	۱۲
لیست چالد backward		۱۴۶۳۱	۱۱۸۰۹	۱۱۷۸۱۳	۱۱۷۸۱۳	۱۲۶۲	۱۲۳۶۶۹	۹۶۷۱
تعداد کاربر منحصربه فرد		۲۷۸۱	۱۴۴۱	۳۱۱	۱۲۴۵	۵۷۰	۱۰۰	۹۲۴
میزان تغییرات در تعداد کاربر		۲۱,۱۹-	۱۹,۱	۰,۴۳-	۰	۳۹,۴۱-	۶,۰۳-	-
میزان مشاهده صفحات		۴,۱۸	۶,۱۹	۳,۳۳	۳,۷	۳,۱	۲,۴	۵
زمان پارگاری صفحات (انفیه)		۳۱۶۲	۱۵۹۴	۳۸۱۱	۲۷۰۴	۲۴۶۴	۴۱۲۵	۳۹۴۳
جایگاه وبسایت در جستجو گوگل		-	۹	۱۳	-	۳۹۴	-	۱۹
محظوظی چند رسانه ای		۵۰-	۵۰	۵۴,۷۵	۲۵,۵	۵۰,۷۵	۲۰,۵	۱۰,۳۰
میزان فاصله از ایده آل +		۶۸۹۱۹,۹۱	۵۷۷۷۷,۰۵	۶۹۰,۸۰,۷	۶۹۰,۶۸,۵۸	۶۸۵۶۸,۳۹	۶۸۰,۹,۱۱	۶۹۸۳۱,۳۹
میزان فاصله از ایده آل -		۶۹۱۶۶,۹۸۸	۶۹۲۵۸۲۹	۶۹۱۰,۶۸	۶۷۳۳,۲۷۷	۶۷۱۴۵۷۶	۶۷۹۶,۹۱۹	۶۳۴۷۵,۰,۱۷
زودیکی نسبی به راه حل ایده آل میبین		۰,۹۰۷۳۷۴	۰,۹۰۸۷۷۸	۰,۹۰۹۰۴۵	۰,۹۱۰۷۰۴	۰,۹۱۱۱۷۱۹	۰,۹۱۶۶۸۶۱	-

ردیه	نام وبسایت	Sciencemag.com	Isna.ir	Khabaronline.ir	Javanemooz.com	Khabaryaab.com	News.ir	Yjcir
۲۲	ردیه صفحه گوگل	۸	۶	۵	۳	۳	۴	۶
۲۳	امتیاز موتور جستجو	۶۴	۵۷	۵۷	۵۰	۴۸	۳۰	۴۵
۲۴	ردیه توافق اکسا	۱۴۳۵	۳۷	۲۹	۱۱۱۵	۳۷۹۲	۹۹	۱۳۰
۲۵	عمرو احمد (۵۰)	۲۱۲,۲۸۴۹	-	-	۵۳۰,۸۸۴۹۳	۴۷,۷۶۹۸۶	-	-
۲۶	میاگین تعداد نمایه در موثرهای جستجو	۳۵۶۶۹۴,۳	۲۶۱۱۸,۰,۷	۲۵۶۳۹۷,۳	۲۵۶۳۹۷,۳	۲۱۵۶۹۱,۷	۱۹۱۴۸,۷	-
۲۷	خطا در کد HTML	۱۴۰۲۳	۵۹	۴۹۹	۳۲	۲۹	۱۵	۱۹
۲۸	لیست‌های backward	۳۱۹۴۶	۹۳۱۰	۹۸۷	۱۷۰	۲۵۸۳	۶۷۸۱۰	-
۲۹	تعداد کاربر منحصربه‌فرد	۷۷۷	۸۵۷	۱۰,۷	۱۰,۷	۲۳۳	۴۹۷۱	-
۳۰	میزان تغیرات در تعداد کاربر	۲۱۴	۰,۳۱-	۰,۳۲-	۰,۳۰-	۱۱,۱	۵-	-
۳۱	میزان مشاهده صفحات	۱,۸۰	۴,۱۱	۳,۴۶	۳,۱۵	۲,۱۵	۰,۲۱	۴,۵۱
۳۲	زمان پارکداری صفحات (انفیه)	۳۰۲۱	۱۵۶۶	۲۱۷۵	۴۶۴۸	۱۸۴۳	۱۹۶۷	۱۶۲۱
۳۳	جایگاه وبسایت در جستجو گوگل	-	۵۶	۱۳۹	-	۱۳۲	۱۵	-
۳۴	محظوظی چندرسانه‌ای	۳,۵	۱۶,۳۵	۳۴,۷۵	۹,۵	۱۲,۷۵	۲۴,۵	-
۳۵	میزان فاصله از ایده آل +	۶۸۴۹۴,۴۵	۷۰,۰۰,۶,۰,۸	۷۰,۹۳,۰,۵	۷۰,۶۹,۰,۶	۶۹۹,۰,۵,۳۳	۷۰,۷۹,۰,۳۴	۷۱,۹۴,۳
۳۶	میزان فاصله از ایده آل -	۶۱۸۷,۵۶۹	۶۲۲۸,۶۹۴	۶۱۹۵,۰۴۹	۵۷,۹,۶۹۷	۵۶۸,۰,۵۳۱	۵۵۱۳,۵۷۲	-
۳۷	زندگی نسبی به راه حل ایده آل مثبت	۰,۹۱۷۱۶	۰,۹۱۷۱۲	۰,۹۱۷۱۵	۰,۹۱۷۱۵	۰,۹۱۷۱۵	۰,۹۱۷۱۵	۰,۹۱۷۱۵

۳۰	Jarchi.ir	زیب
۳	Irib.ir	نام و بسیارت
۴۰		رتبه صندحه گوگل
۹۳		امتیاز موتور جستجو
۱۱۹		رتبه ترافیک اکتسا
۱۲۰		عمر دامنه (ماه)
۷		میاگین تعداد نمایه در موتورهای جستجو
۱۷۴۳۶۳۰,۳		۱۹۸۳۴۶,۷
۸۸		خطا در کد HTML
۱۵۳		لیست های backward
۱۴۷۷۲		تمداد کاربر منحصر به فرد
۷۸۹		میزان تعییرات در تعداد کاربر
۴۰۹		میزان مشاهده صفحات
۳۳		زمان پارک کاری صفحات (اینیه)
۷۶,۲۹		جایگاه و بسیارت در جستجو گوگل
۳۰۴		محنتوای چند رسایه ای
۱۷۱۳		میزان فاعله از ایده آل +
۱۹۹۰		میزان فاعله از ایده آل -
۱,۲۵		میزان قابلیت ایده آل
۷۱۰,۸۷۷,۴۹		میزان قابلیت ایده آل
۷۱۰,۸۷۷,۴۹		نرم افزارهای موبایل
۵۴۹۰,۸۷		نرم افزارهای موبایل
۵۲۵۰,۵۳		نرم افزارهای موبایل
۹۲۸۲۹۷		نرم افزارهای موبایل
۰,۹۳۱۵۷۸		نرم افزارهای موبایل

با توجه به اثبات کارایی مدل‌های تصمیم‌گیری چندمعیاره می‌توان چنین فرض کرد که نتایج خروجی حاصل از روش «تاپسیس»، رتبه‌بندی را به دست می‌دهد که به عنوان داده‌های یادگیری و آزمون در روش یادگیری ماشین به منزله خروجی مورد انتظار استفاده شود، یعنی بردارهایی از ویژگی کیفیت وب‌سایتها به همراه خروجی رتبه آن‌ها حاصل می‌گردد که برای یادگیری و آزمون در روش یادگیری ماشین قرار است از آن‌ها استفاده شود.

۳-۴. استفاده از روش یادگیری ماشین

از دو روش شبکه عصبی و ماشین بردار پشتیبان برای پیش‌بینی مقادیر جدید استفاده گردیده است که کلیت مدل استفاده شده در زیر توصیف می‌شود.

به صورت کلی، در بررسی هایی که به عنوان خروجی سیستم ارزیابی کیفیت خودکار و بسایت ها انجام شد، به این نتیجه رسیدیم که بیان یک رتبه به عنوان خروجی نهایی، نه تنها ممکن است تأثیر زیاد خوبی بر رقابت سالم در حوزه کسب و کار نداشته باشد، بلکه ممکن است با درنظر گرفتن شاخص های دیگر یا رقابت تنگاتنگی که رتبه های نزدیک با یکدیگر دارند، به جای سیستم رتبه دهی عددی از یک الی آخر به دست آمده از روش «تابسیس» به جای رتبه دهی دستی، رتبه بندی نهایی را به طیفی از طبقه های شش گانه «بسیار عالی»، «عالی»، «خوب»، «متوسط»، «ضعیف» و «بسیار ضعیف» نگاشت کیم. برای این کار، توزیعی نرمال از رتبه های نهایی از ۱ تا ۷۹۱ را در نظر گرفته و تلاش شده است تا فاصله بین رتبه ها به صورت آماری استخراج گردد.

بنابراین، بر اساس توزیع نرمال با میانگین $= ۳۹۶$ و $\sigma = ۴۸$ بازه‌های طبقه‌های تعیین شده بر اساس رتبه‌هایی که در روش «تاپسیس» به دست آمده، به شرح جدول ۴ است.

جدول ۴. محدوده دسته‌بندی طبقات وب‌سایت‌ها

نام طبقه	بازه رتبه
بسیار عالی	۶۲-۱
عالی	۲۲۹-۶۳
خوب	۳۹۶-۲۳۰
متوسط	۵۶۳-۳۹۷
ضعیف	۷۳۰-۵۶۴
بسیار ضعیف	۷۹۱-۷۳۱

نام طبقات، برچسبی به عنوان طبقه وب‌سایت‌ها محاسبه می‌شود که برای انجام محاسبات به ترتیب، عدد ۶ تا ۱ به این برچسب‌ها اطلاق می‌گردد. بنابراین، اعداد ۱ تا ۶ به عنوان خروجی در روش یادگیری ماشین مورد استفاده قرار می‌گیرند.

پیش‌پردازش داده‌ها در هر دو روش شبکه عصبی و ماشین بردار پشتیبان مشابه است، بنابراین شرح پیش‌پردازش داده‌ها در این روش‌ها به صورت مستقل از روش در ادامه بیان می‌شود. در هر دو روش یادگیری ماشین با روش تحلیل اجزای اصلی، ابعاد بردار ورودی کاهش داده شده و داده‌ها نرم‌الایز گردیده است.

۳-۴. پیش‌پردازش داده‌ها

معمولًا قبل از آغاز آموزش در روش‌های یادگیری ماشین یک سری پیش‌پردازش بر روی داده‌ها انجام می‌شود، از قبیل نرم‌الایز کردن داده‌ها و قراردادن آن‌ها در یک فاصله مشخص مانند بین ۱ و -۱، که باعث افزایش کارایی روش مورد استفاده می‌شود. در بعضی وضعیت‌ها ابعاد بردار ورودی بسیار بزرگ است، اما اجزای بردارها همبستگی بالایی دارند. مفید است که در این وضعیت ابعاد بردار ورودی را کاهش دهیم. یک رویه مناسب برای این عمل استفاده از آنالیز اجزای اصلی است. این تکنیک سه تأثیر دارد: ۱) این عمل منجر به معتمدسازی اجزاء بردار ورودی می‌گردد، بنابراین آن‌ها هیچ وابستگی با یکدیگر نخواهند داشت؛ ۲) این کار اجزای معتمد حاصل را مرتب می‌کند و مؤثرترین آن‌ها در اولین اولویت قرار می‌گیرد؛ و ۳) در نتیجه، می‌توان اجزایی را که تغییرات کوچک‌تری در مجموعه داده‌ها ایجاد می‌کنند، حذف کرد.

(Shlens 2006)

در روش تحلیل اجزای اصلی^۱ (PCA) پایه‌هایی که بهترین توزیع داده را داشته باشند، استخراج می‌شوند (همان). آنالیز اجزای اصلی برای ناهمبسته کردن داده‌ها مفید است و تبدیلی ایجاد می‌نماید که داده‌ها را در جهت‌های متعامد با بیشترین دامنه تغییرات تصویر می‌کند. همچنین، آنالیز اجزای اصلی با تقلیل ابعاد از $p \leq n$ به n برای کدکردن فشرده داده‌ها نیز قابل استفاده است. یعنی با استفاده از آنالیز اجزای اصلی، بدون ازدست‌رفتن قسمت عمده اطلاعات، اجزای وابسته به تغییرات کم، از داده حذف می‌شود (گشمرد و دیگران، ۱۳۹۰). حذف این عناصر اضافی سرعت آموزش شبکه‌های عصبی و ماشین بردار پشتیبان را افزایش می‌دهد و در صورتی که ابعاد مسئله خیلی بزرگ باشد، کارایی آن‌ها را بهبود می‌بخشد. علاوه بر این، بعد از اعمال این روش، داده‌های ورودی نرمال شده و دارای میانگین صفر و انحراف معیار واحد می‌گردند.

۲-۴-۳. روش شبکه عصبی مصنوعی

در این قسمت از یک شبکه پرسپترون چندلایه استفاده شده است که نشان‌دهنده ارتباطی غیرخطی بین بردار ورودی‌ها و خروجی‌ها می‌باشد. این ارتباط از طریق اتصال نورون‌های هر لایه، در لایه‌های قبلی و بعدی است. خروجی نورون‌ها در ضرب‌ایب وزنی ضرب می‌شوند و به عنوان ورودی به تابع غیرخطی انتقال داده می‌شود. در مرحله آموزش، به پرسپترون داده‌های آموزشی آموزش داده می‌شود. سپس، وزن‌های شبکه به گونه‌ای تنظیم می‌شوند که خطاً بین خروجی پیش‌بینی شده و هدف، کمینه گردد و یا اینکه تعداد دفعات آموزش به مقدار حداقل از پیش تعیین شده برسد. سپس، به منظور سنجش اعتبار آموزش انجام شده، تعدادی از داده‌های ورودی مورد آزمون قرار نگرفته به شبکه اعمال می‌شود. این مدل، شامل سه لایه ورودی، مخفی و خروجی است که تعداد سلول‌های هر لایه به روش سعی و خطأ مشخص می‌گردد. سیگنال‌های ورودی به‌وسیله ضربی‌های بهنجار کننده به مقدار یک نرمالیزه شده و بعد از محاسبات، خروجی به مقدار واقعی برگردانده می‌شود. همچنین، مقادیر اولیه وزن‌ها به صورت اتفاقی در نظر گرفته شده‌اند. این شبکه اصولاً بر مبنای الگوریتم پس انتشار خطأ آموزش می‌بیند. بدین ترتیب که خروجی‌های واقعی با خروجی‌های دلخواه مقایسه می‌شوند و وزن‌ها به‌وسیله الگوریتم پس انتشار، به صورت تحت نظرارت تنظیم می‌گردد تا الگوی مناسب به وجود آید.

در این قسمت، ابتدا مقادیر ویژگی‌های ۱۳ گانه هر وب‌سایت نرم‌افزاری شده و مقادیر ورودی

1. principal components analysis

به یک بازه بین [۱ و -۱] نگاشت گردیده‌اند. در این مرحله از پیش‌پردازش داده‌ها، همان‌طور که بیان شد، از تحلیل اجزای اصلی استفاده گردیده است و در نهایت، همان‌طور که در ادامه بیان می‌گردد، تقسیم داده انجام شده و با شبکه عصبی مصنوعی طراحی شده، مجموعه داده‌ها مورد آزمایش و آزمون قرار گرفته‌اند. برای انجام محاسبات یادگیری ماشین از نرم افزار Matlab استفاده گردیده است. بعد از نرمالایز کردن داده‌ها و کاهش وابستگی و ابعاد آن‌ها، مرحله بعدی تقسیم داده‌ها می‌باشد.

۴-۳. تقسیم داده‌ها

تقسیم داده در زمانی که تنها یک مجموعه داده در دسترس است، کاری ضروری است که به صورت تقسیم داده‌ها به بخش‌های دوتایی یا سه‌تایی انجام می‌گردد و تعیین نسبت تعداد داده‌ها در مجموعه‌های داده‌ای متفاوت می‌باشد. از آنجا که با وجود بخش داده‌های ارزیابی امکان رسیدن به جوابی بهتر برای پیش‌بینی داده‌ها وجود دارد، باور بیشتر متخصصان بر این است که ۷۰ درصد داده‌ها به صورت تصادفی برای آموزش شبکه عصبی، ۱۵ درصد داده‌ها به صورت تصادفی برای صحت و اعتبارسنجی و ۱۵ درصد دیگر داده‌ها به صورت تصادفی برای آزمایش و آزمون شبکه عصبی مورد استفاده قرار گیرد (Gallagher 1999). در مطالعه حاضر برای روش شبکه عصبی مصنوعی نیز روند تقسیم‌بندی داده‌ها به همین شیوه بوده است.

۴-۳-۱. تعیین معماهی شبکه

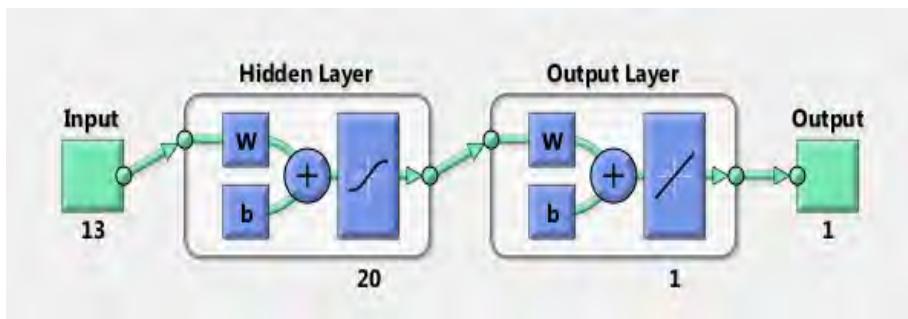
از یک شبکه پیش‌خور دو لایه به عنوان ساختار شبکه عصبی استفاده شده است که در لایه مخفی اولیه از تابع انتقال «سیگموئید»^۱ و در لایه خروجی دومی از تابع انتقال خطی استفاده گردیده است. معماهی این شبکه عصبی پیش‌خور دولایه در شکل ۳ نشان داده شده است.

۴-۳-۲. انتخاب روش یادگیری

شبکه با الگوریتم پس انتشار «لونبرگ-مارکوارت»^۲ آموزش داده شده است.

۴-۳-۳. تعیین پارامترهای شبکه عصبی

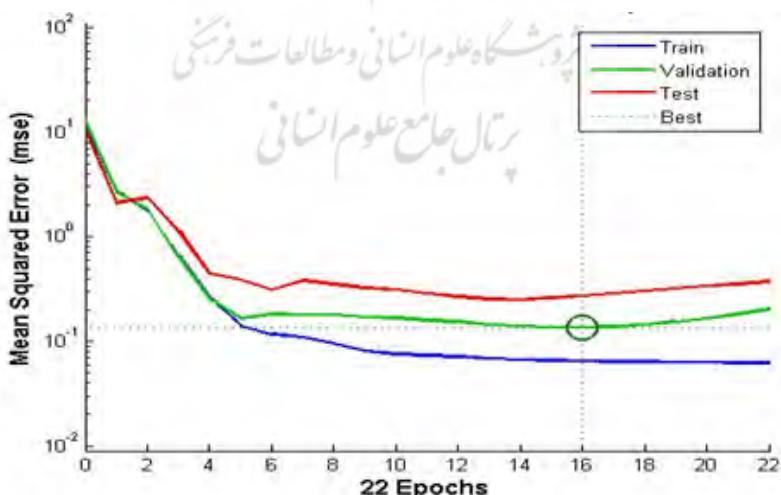
به صورت آزمون و خطای سعی در به دست آوردن پارامترهای شبکه عصبی گردید و در نهایت، بدین نتیجه رسیدیم که از ۲۰ نورون به عنوان نورون‌های مخفی شبکه استفاده نماییم. شبکه عصبی که در نهایت مورد استفاده قرار گرفت، در شکل ۳ نمایش داده شده است.



شکل ۳. نمایی از شبکه عصبی مورد استفاده در پژوهش

۴-۳-۴. آموزش و آزمون داده‌ها

داده‌ها با استفاده از شبکه عصبی طراحی شده آموزش داده شده و مورد آزمون قرار گرفته‌اند. معیار ارزیابی شبکه‌ای که طراحی گردیده، میانگین مربعات خطأ (MSE) می‌باشد. این میانگین هر چقدر کوچک باشد، بهتر است. این میزان در شبکه عصبی طراحی شده برابر با 0.0620×10^{-3} می‌باشد که خروجی خطای آن در نمودار ۱ نشان داده شده است. همان‌طور که مشاهده می‌شود مقدار میانگین خطأ در ابتدا زیاد بوده، ولی با تکرار آموزش و آزمون، میزان میانگین خطأ کاهش پیدا کرده است. بعد از تکرار ۱۶، مقدار پیش‌بینی در مجموعه اعتبارسنجی به صورت ۶ بار به صورت مستمر اشتباه بوده است که به‌همین دلیل آموزش داده‌ها برای جلوگیری از برآذش داده‌ها به پایان رسیده است و مقدار میانگین خطأ با کمترین مقداری که تا آن لحظه داشته، برابر گردیده است.



نمودار ۱. نمودار میزان میانگین خطأ

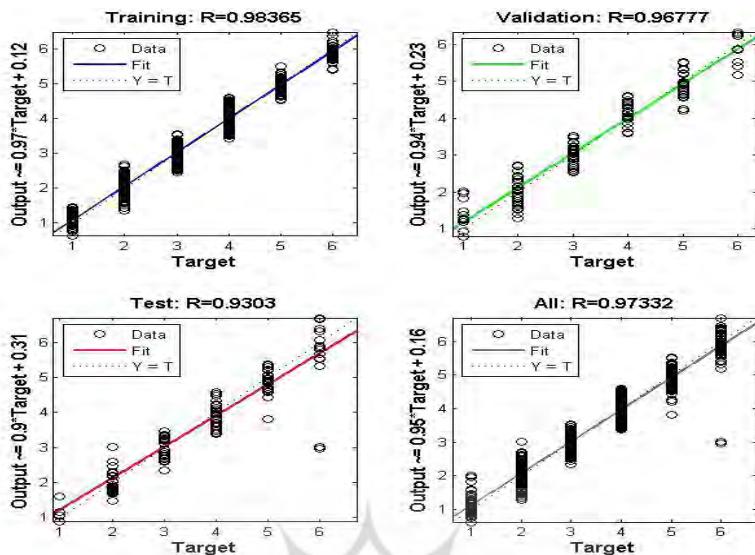
در نمودار ۱ می‌توان ضریب تشخیص سیستم را به عنوان معیاری برای اعتبارسنجی سیستم مشاهده نمود که مقدار آن برابر با ۰/۹۷۳۳۲ است.

۴-۴. روش ماشین بردار پشتیبان

در این روش که با استفاده ازتابع‌های آماده در نرم‌افزار Matlab فراهم شده، ابتدا به دلیل ازدیاد ابعاد ویژگی‌های مسئله، ابعاد ورودی‌ها کاهش یافته و داده‌ها نرمالایز گردیده‌اند و بعد از تقسیم مجموعه داده، با استفاده از روش ماشین بردار پشتیبان یکی در برابر همه، k تا SVM تشکیل می‌شود، که k در اینجا تعداد کلاس‌هاست و در نهایت، میزان پیش‌بینی سیستم سنجیده می‌شود. بعد از پیش‌پردازش بردارهای ورودی با روش تحلیل اجزای اصلی شرح فعالیت‌های فرایند انجام این روش به شرح زیر می‌باشد:

۴-۴-۱. تقسیم داده‌ها

در این روش مجموعه داده‌ها به دو بخش داده‌های آموزشی و آزمون تقسیم می‌گردد. در روش ماشین بردار پشتیبان، روش‌های مختلفی برای تعیین نسبت مجموعه داده آموزش به آزمون وجود دارد، که یا از طریق فرمول‌هایی بر اساس عواملی از قبیل پارامترهای دخیل در روش، تعداد کلاس‌ها و تعداد کل مجموعه داده تعیین می‌شوند یا به واسطه روش‌های آزمون و خطای نسبت‌های مختلف بهینه‌ای برای مجموعه داده‌ها تعیین گردیده است (Guyon 1997). یکی از این بهترین نسبت‌های تقسیم داده‌ها برای مجموعه داده‌های آموزشی و آزمون نسبت ۶۰ درصد به ۴۰ درصد است (Andrew Ng, John Duchi). بر اساس نسبت پیشنهادی، در این پژوهش در حدود ۶۰ درصد از مجموعه داده‌ها (۵۰۰ نمونه) به عنوان مجموعه داده آموزش و بقیه آن‌ها (۲۹۱) به عنوان مجموعه آزمون در نظر گرفته شده‌اند. البته، با روش آزمون و خطای مشاهده میزان خطای در هر سری، می‌توان نسبت بهینه این درصد را خاص هر مجموعه داده هم به دست آورد که در رابطه با این مجموعه داده، و میزان اندک‌بودن میزان خطای نهایی حاصل شده در این مقدار نسبت، از مناسب‌بودن آن به صورت شهودی هم می‌توان مطمئن بود. نمودارهای رگرسیون هر بخش از مجموعه داده‌ها و ضریب تشخیص نهایی آن‌ها در نمودار ۲ نشان داده شده است.



نمودار ۲. نمودارهای رگرسیون هر بخش از مجموعه داده‌ها و ضریب تشخیص نهایی

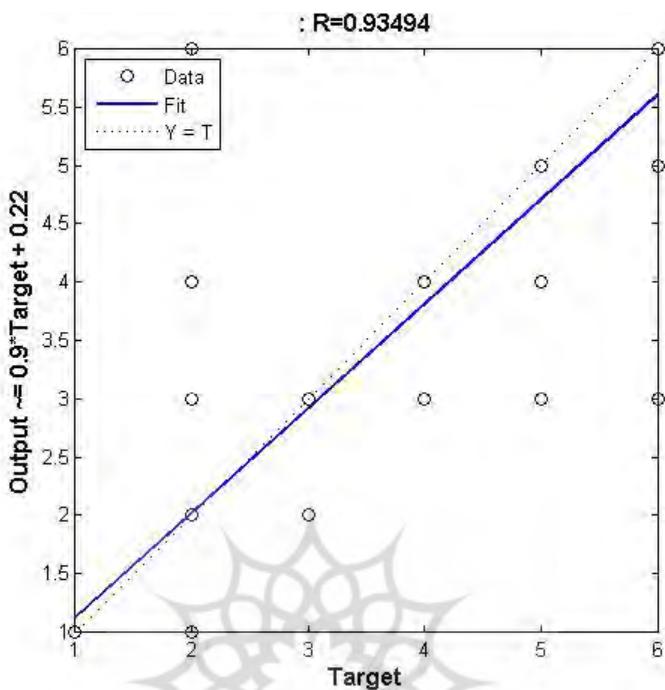
۴-۴-۳. انتخاب تابع هسته و پارامترهای هسته

کل فرایند استفاده از ماشین بردار پشتیبان با دو تابع اصلی SVMtrain و SVMClassify در Matlab صورت گرفته است. در اینجا از هر دو تابع هسته RBF و چندجمله‌ای در ماشین بردار هسته‌ای استفاده شده و مقدار پارامتر آن‌ها همان مقدار پیش‌فرض در خود نرم‌افزار در نظر گرفته شده است.

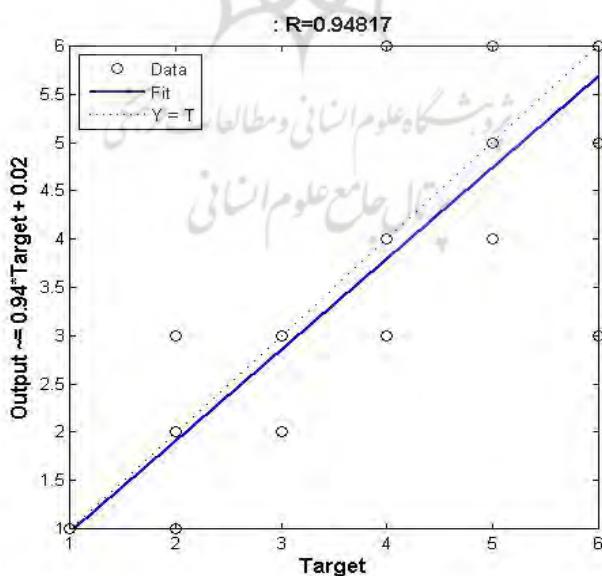
۴-۴-۴. آموزش مجموعه داده‌های آموزش و آزمون داده‌ها

در نهایت، مجموعه داده‌های انتخابی برای آموزش مجموعه داده، آموزش داده شده و پس از تست داده‌ها، مقدار نرخ پیش‌بینی درست برای مجموعه داده‌های آزمون تعیین گردیده است. این مقدار برای ماشین بردار پشتیبان با تابع هسته RBF طراحی شده به صورت $CCR = ۰/۸۰۷۶$ می‌باشد. علاوه بر این، میزان ضریب تشخیص که در نمودار ۳ نمایش داده شده برابر با $۰/۹۴۸۱۸$ می‌باشد.

همچنین، مقدار نرخ پیش‌بینی درست برای ماشین بردار پشتیبان با تابع هسته چندجمله‌ای طراحی شده به صورت $CCR = 0.8488$ می‌باشد. علاوه بر این، میزان ضریب تشخیص برای این سیستم ماشین بردار پشتیبان برابر با $0/۹۳۴۹۴$ بوده که در نمودار ۴ نمایش داده شده است.



نمودار ۴. نمودار ماشین بردار پشتیبان با تابع هسته چندجمله‌ای

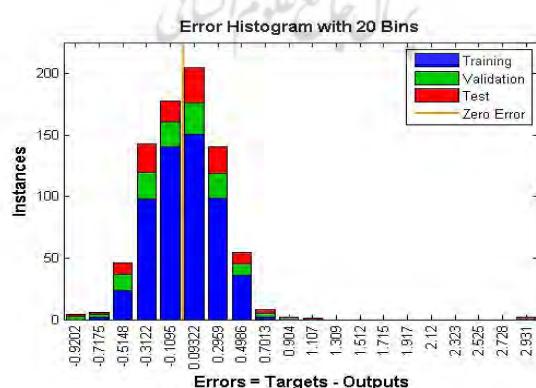


نمودار ۳. نمودار رگرسیون ماشین بردار پشتیبان با تابع هسته RB

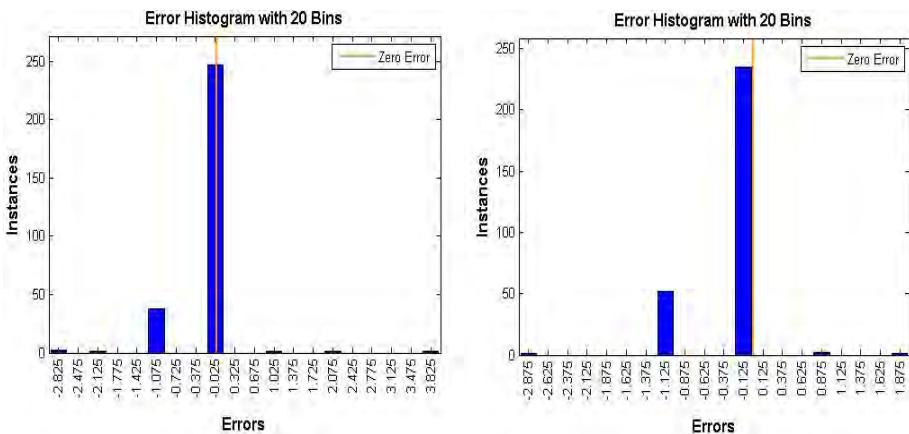
۴. یافته‌های پژوهش

بعد از به دست آوردن لیستی از ۱۳ شاخص مهم برای ارزیابی کیفیت وب‌سایت‌ها که در پاسخ به سؤال اول پژوهش صورت گرفت، و آموزش و اجرای شبکه عصبی با داده‌های جمع آوری شده، می‌توان به پاسخ پرسش دوم رسید که امکان طراحی سیستمی به صورت خودکار با استفاده از روش‌های یادگیری ماشین امکان‌پذیر است. همان‌طور که در نمودار ۵ دیده می‌شود، میزان خطایی که در پیش‌بینی خروجی داده‌های جدید به عنوان داده‌های آزمون وجود دارد، بسیار اندک بوده و همگی به مقدار عددی صفر متایل هستند. پس، می‌توان به این نتیجه رسید که با دقت بسیار زیاد امکان استفاده از روش‌های یادگیری ماشین، به ویژه شبکه عصبی مصنوعی برای پیش‌بینی طبقه وب‌سایت‌ها وجود داشته و می‌توان مطمئن شد که در صورت اضافه شدن وب‌سایتی با داده‌های جدید، طبقه این وب‌سایت بسیار به سرعت شناسایی شده و در طبقه مورد نظر قرار می‌گیرد.

بعد از آموزش و اجرای ماشین بردار پشتیبان به عنوان یکی دیگر از روش‌های یادگیری ماشین می‌توان از نگاهی دیگر دوباره به پاسخ پرسش دوم رسید که امکان طراحی سیستمی به صورت خودکار با استفاده از روش‌های یادگیری ماشین امکان‌پذیر است. همان‌طور که در نمودار ۶ دیده می‌شود، میزان خطایی که در پیش‌بینی خروجی داده‌های جدید به عنوان داده‌های آزمون وجود دارد، در هر دو روش ماشین بردار پشتیبان چه با تابع هسته چندجمله‌ای و چه با تابع RBF بسیار اندک بوده و همگی به مقدار عددی صفر متایل هستند. پس، می‌توان به این نتیجه رسید که با دقت بسیار زیاد امکان استفاده از روش‌های یادگیری ماشین، از جمله ماشین بردار پشتیبان برای پیش‌بینی طبقه وب‌سایت‌های موجود وجود دارد و اضافه شدن وب‌سایت جدید به مجموعه داده‌های موجود امکان‌پذیر است.



نمودار ۵. نمودار هیستوگرام خطای در شبکه عصبی



نمودار ۶. به ترتیب از راست به چپ، هیستوگرام خطای ماشین بردار پشتیبان با تابع هسته RBF و تابع هسته چندجمله‌ای

با انجام مقایسه‌ای بین روش‌های انجام شده بر اساس شاخص‌های اعتبارسنجی که در اینجا از شاخص ضریب تشخیص بهره‌بردایم، می‌توان به این نتیجه رسید که بهترین روش یادگیری ماشین در بین این روش‌ها، همان طور که در جدول ۵ مشاهده می‌شود، شبکه عصبی مصنوعی بوده که ضریب تشخیصی بهتری از ماشین‌های بردار پشتیبان دارد و در کل، میان روش‌های ماشین بردار پشتیبان، تابع هسته RBF ضریب تشخیص بهتری نسبت به تابع هسته چندجمله‌ای دارد.

جدول ۵. ضرایب تشخیص روش‌های به کاربرده شده

روش به کاربرده شده	ضریب تشخیص
شبکه عصبی	۰,۹۷۳۳۲
ماشین بردار پشتیبان (تابع هسته RBF)	۰,۹۴۸۱۷
ماشین بردار پشتیبان (تابع هسته چندجمله‌ای)	۰,۹۳۴۹۴

۵. نتیجه‌گیری و پیشنهادها

امروزه با توجه به اهمیت وب‌سایت‌های خبری به عنوان منابع مهمی از اطلاعات برای شهر وندان یک جامعه، این پژوهش به مطالعه و بررسی این وب‌سایت‌ها و ارائه راهکار مناسبی برای ارزیابی خودکار آن‌ها به منظور ایجاد پایه‌ای برای مقایسه جایگاه آن‌ها پرداخته است. نتایج اکثر پژوهش‌های پیشین انجام شده در ارتباط با وب‌سایت‌های خبری می‌تواند به عنوان

مبنا بر این در طراحی این دسته از وب‌سایت‌ها در ایران استفاده شود. در واقع، تا کنون خدمات اساسی شناسایی شده در ارتباط با نوع کسب و کار این نوع وب‌سایت‌ها، مبنا و گام اولیه طراحان این وب‌سایت‌ها در راستای ایجاد آن به شمار می‌رود که می‌توانند به افزایش کیفیت و در نتیجه آن، افزایش دفعات بازدید از وب‌سایت منجر شوند. اما پژوهش پیش رو، صرفاً از شناسایی این ویژگی‌ها فراتر رفته و به دنبال ارزیابی این وب‌سایت‌ها به صورت کاملاً خود کار است، به گونه‌ای که در هیچ‌کدام از مراحل جمع آوری اطلاعات، وزن دهی به معیارها و در نهایت، ارزیابی، هیچ عامل انسانی در این فرایند دخیل نباشد.

در این پژوهش ابتدا با استفاده از ادبیات تحقیق، ۱۳ عامل اصلی که در ارزیابی خود کار وب‌سایت‌های خبری می‌توانند مورد استفاده قرار گیرند، شناسایی شدند. این عوامل، همان‌طور که بیان شد، ۱۳ عامل مهم برای ارزیابی کیفیت وب‌سایت‌ها هستند که تنها با دانستن منبع جمع آوری داده‌های آن‌ها با استفاده از روش‌های خود کار، قابل گردآوری می‌باشد. قابل ذکر است که در این مقاله، برای اولین بار مجموعه‌ای از شاخص‌های ارزیابی خود کار و وب‌سایت‌ها که می‌تواند در پژوهش‌های مشابه استفاده شود، در کنار یکدیگر بیان می‌گردد. در پژوهش‌های مشابه، یا جامعیت این شاخص‌ها به این تعداد نیست، یا در نهایت، در کنار این شاخص‌ها از عوامل دیگری که داده‌های آن‌ها به صورت دستی و توسط پرسش‌نامه از کاربران یا خبرگان حاصل شده بود، استفاده گردیده است. سپس، با استفاده از خزشگرهای خود کار از منابع موجود در وب، داده‌های مرتبط با این ۱۳ عامل، برای ۷۹۱ وب‌سایت خبری که توسط کاربران ایرانی بیشترین مشاهده را توسط آمار «الکسا» دارند، استخراج گردیده‌اند. بدین صورت، مجموعه اطلاعاتی که در این پژوهش برای طراحی سیستم خود کار می‌توانند مورد استفاده قرار گیرند، حاصل گردیده است. بعد از آن، نوبت به طراحی سیستمی برای ارزیابی خود کار و وب‌سایت‌های فارسی رسید که ابتدا از ترکیب روش «تاپسیس» و آنتروپی اطلاعات، خروجی‌های سیستم برای یادگیری با نظارت استخراج گردیدند. اما، از آنجا که رتبه‌دهی عددی، صرفاً روش خوبی برای رقابت میان وب‌سایت‌ها نبود، ۶ طبقه بسیار ضعیف تا بسیار عالی برای نگاشت این اعداد در این طبقه‌ها استفاده شد و این ۶ طبقه به عنوان خروجی‌های یادگیری با نظارت در دو روش یادگیری ماشین، شبکه عصبی و ماشین پشتیبان استفاده شد.

همان‌طور که از یافته‌های این پژوهش بر می‌آید، بهترین روش برای ارائه سیستم خود کار برای ارزیابی کیفیت وب‌سایت‌های خود کار، روش شبکه عصبی به نسبت روش ماشین بردار پشتیبان می‌باشد. شبکه عصبی با ضریب تشخیص ۰/۹۷۳۳۲ در صدر لیست روش‌های یادگیری ماشین مناسب برای ارزیابی کیفیت وب‌سایت‌ها در این پژوهش می‌باشد.

علاوه بر این، سیستم طراحی شده مตکی بر ثابت بودن مقادیر و تعداد شاخص‌ها نیست و با گذشت زمان و تغییر در این عوامل، امکان ارزیابی و طبقه‌بندی بلاذرنگ مجدد وب‌سایت‌ها امکان‌پذیر است. همان‌گونه که با افزایش روزافرونه تعداد وب‌سایت‌ها، امکان ارزیابی بیش از ۷۹۱ وب‌سایت به کاررفته در سیستم هم به صورت لحظه‌ای امکان‌پذیر است و این سیستم وابسته به تعداد ثابتی از وب‌سایت‌ها نیست.

گفتی است در هیچ‌یک از مقاله‌های مرور شده، برای ارزیابی خودکار وب‌سایت‌ها، جمع‌آوری اطلاعات به صورت خودکار نبوده و برای ارزیابی وب‌سایت‌ها در حوزه وب‌سایت‌های ایرانی اولین‌بار است که برای پیش‌بینی رتبه وب‌سایت‌های خبری در آینده از سیستم‌های مبتنی بر یادگیری ماشین استفاده گردیده است.

با ارائه این سیستم، وب‌سایت‌های خبری از قبیل «رویترز»، «سینت»، «قطره»، «روور»، «ویستا»، «اسکای اسپرت»، «خبر فارسی»، «حراسان‌نیوز»، «جامانیوز»، «مهرنیوز»، «افکارنیوز»، «تابناک»، «عصر ایران»، «ایسنا»، «خبر آنلاین»، «باشگاه خبرنگاران جوان»، «ساینس‌مگ» و «الجزیره» از قبیل سایت‌هایی هستند که در طبقه‌بسیار عالی قرار گرفته‌اند. از نکات مهمی که می‌توان نتیجه گیری کرد، اینکه در پر مشاهده‌ترین وب‌سایت‌های با کیفیت خبری توسط کاربران ایرانی، در کنار وب‌سایت‌های خارجی، تعداد زیادی از وب‌سایت‌های داخلی قرار گرفته‌اند که خود می‌تواند نشان از حضور وب‌سایت‌های داخلی کشور در عرصه رقابت در کنار وب‌سایت‌های نمونه خارجی برای جذب بیشتر بازار و کاربران داخلی ایران باشد. علاوه بر این، نوع وب‌سایت‌های موجود در طبقه‌بسیار عالی، مشتمل بر نوع وب‌سایت‌های خبری عمومی تا وب‌سایت‌های خبری در حوزه خاصی از قبیل ورزشی، علمی یا فناوری می‌باشد و توزیعی از وب‌سایت‌های برتر خبری در هر حوزه را می‌توان به راحتی با این روش شناسایی کرد.

این سیستم به عنوان سیستمی برای رتبه‌دهی به وب‌سایت‌ها به صورت بسیار کلی، و نه تنها در زمینه وب‌سایت‌های خبری، قابل تعیین می‌باشد. برای اغلب وب‌سایت‌های اطلاعاتی مانند وب‌سایت‌های اجتماعی و وب‌سایت‌های سازمان‌ها در صورتی که فقط به منظور اطلاع‌رسانی باشند، می‌تواند به کاربرده شود. همچنین، برای دیگر وب‌سایت‌ها مانند وب‌سایت‌های حوزه تجارت الکترونیک با اضافه کردن شاخص‌هایی از قبیل اعتماد و حریم شخصی و جمع‌آوری داده‌های مناسب می‌توان این وب‌سایت‌ها را هم با این روش رتبه‌بندی نمود.

در صورت اجرایی شدن سیستم ارائه شده، اولین سیستم خودکار رتبه‌دهی وب‌سایت‌ها را در ایران برای ارزیابی کیفیت آن‌ها به صورت تجاری خواهیم داشت. علاوه بر این، بنا بر تعیین ارزش شاخص‌ها و اهمیت نسبی آن‌ها، بهتر است وب‌سایت در جهت افزایش مقدار شاخص‌هایی که

بستگی به مالک وب‌سایت دارد، تلاش نماید. به عنوان مثال، سابقه فعالیت وب‌سایت از مواردی نیست که مالک وب‌سایت قادر به افزایش میزان آن باشد، ولی موردنی چون کاهش خطاهای HTML جزء مواردی است که در جهت افزایش رتبه بهتر می‌توان به بهبود آن اقدام نمود. همچنین، صاحبان وب‌سایت‌های خبری و سازمان‌های اطلاع‌رسانی که اولین هدف آنان کسب میزان مشاهده کننده بیشتر است، با استفاده از این سیستم می‌توانند جایگاه خود نسبت به بقیه رقبا را در کم نموده و در جهت افزایش آن اقدام نمایند.

پژوهشگران در تحقیقات آتی خود می‌توانند از امکان افزایش شاخص‌های دیگری برای ارزیابی وب‌سایت‌ها که بیشتر متکی به خود وب‌سایت باشد، استفاده کنند مانند قابلیت سنجش رنگ وب‌سایتی با ایجاد سیستم ماشین بردار پشتیبان برای مشابهت رنگ بقیه وب‌سایت‌ها به وب‌سایت برتر، یا اضافه کردن شاخص کپی‌بودن یا نبودن محتوا که به صورت میانگین بر روی پست‌های اخیر خبری با استفاده از روش‌هایی مانند هشینگ¹ قابل انجام است، یا افزایش شاخصی که این سیستم را بیشتر بومی نماید، مانند مکان سرور که به‌نحوی می‌تواند به عنوان شاخص زمان پاسخگویی از سرور استفاده شود. علاوه بر این می‌توانند در روش‌های یادگیری ماشین از روش‌های تکاملی برای مشاهده بهبود میزان پیش‌بینی استفاده کنند یا اینکه با تمامی شاخص‌های اعتبار‌سنجد و مقایسه آن‌ها برای اطمینان بیشتر، اعتبار‌سنجد سیستم انجام شود.

فهرست متابع

- پاشازاده، فریبا، و محسن حاجی‌زین‌العابدینی. ۱۳۸۸. وب کیوام رویکردی کمی جهت ارزیابی کیفی وب‌سایت کتابخانه‌ها. بابل: همایش منطقه‌ای وب‌سایت کتابخانه‌های دانشگاهی چنگیز، نفیسه. ۱۳۸۵. ابزارهای کیفیت خودکار وب‌سایت با تأکید بر کاربرد پذیری آن‌ها. تحقیقات کتابداری و اطلاع‌رسانی دانشگاهی ۴۵: ۱۴۷-۱۶۲.
- حسن‌زاده، محمد، و فاطمه نویدی. ۱۳۸۹. مقایسه کاربرد انواع روش‌های ارزیابی دسترس‌پذیری وب‌سایت‌ها (مورد مطالعه و وب‌سایت وزارت‌خانه‌های دولت جمهوری اسلامی ایران) مجله تحقیقات اطلاع‌رسانی و کتابخانه‌های عمومی ۲۸: ۵-۶.

حسین‌زاده، حسین. ۱۳۷۹. کتاب مدیریت کیفیت جامع نگاهی منسجم. تهران: انتشارات دانشگاه تهران، زاهدی، شمس‌السادات. ۱۳۸۹. ارزیابی کیفیت وب‌سایت‌ها ابزارها و معیارها. فصلنامه مدیریت توسعه و تحول ۴: ۵-۱۶.

1. Hashing

- گشمرد، شهرز، علیرضا مهری دهنوی، و حسن ربانی. ۱۳۹۰. استفاده از الگوریتم آنالیز اجزای اصلی جهت تشخیص نرم افزاری حروف در متون فارسی. *ویژه‌نامه مهندسی پزشکی مجله دانشکده پزشکی اصفهان* ۲۹(۱): ۲۲-۱.
- Bauer, Ch., and A. Scharl. 2000. Quantitative evaluation of Web site content and structure. *Internet research* 10 (1): 31-44.
- Cho, J., and R. Adams. 2005. *Page Quality: In Search of an Unbiased Web Ranking*. In Proceedings of the 2005 ACM SIGMOD conference, Baltimore, Maryland, PP.551-562.
- Derhami, V., E. Khodadadian, M. Ghasemzadeh, and A. M. Zareh Bidoki. 2013. Applying reinforcement learning for web pages ranking algorithms. *Applied Soft Computing* 3 (4): 1686-1692.
- Dominic, P., H. Jati, P. Sellappan and G. K. Nee. 2011. A comparison of Asian e-government websites quality: using a non-parametric test. *International Journal of Business Information Systems* 7 (2): 220-246.
- Fang, W. 2007. Using Google Analytics for Improving Library Website Content and Design: A Case Study. *Library Philosophy and Practice* 9 (2): 1-17.
- Gallagher, M. R. 1999. Multi-layer perceptron error surfaces: Visualization, structure and modeling. PhD dissertation, University of Queensland.
- Guyon I., 1997. A scaling law for the validation-set training-set size ratio. *AT&T Bell Laboratories* 1-11.
- Hernandez B., J. Jimenex and M. J. Martin. 2009. Key website factors in e-business strategy. *International Journal of information management* 29 (5): 362-371.
- Hsiu-Fen, L. 2010. An application of fuzzy AHP for evaluating course website quality. *Computers & Education* 54 (4): 877-888.
- Li p., S. Yamada. 2009. Automated Web Site Evaluation – An Approach Based on Ranking SVM, IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technologie. vol. 3, pp: 34-37.
- Ng Andrew and Duchi John., 2014. CS229 Machine Learning Online Course. Spring 2014, Online. Available from: <http://cs229.stanford.edu/> (accessed 25.09.16)
- Reesi Vananie, I, A. Manian, and M. A. Shafia. 2013. Designing a Fuzzy Inference System for Predicting the Implementation Success of ERP Solution. *Journal of Information Technology Management* 5 (1): 98-106.
- Scowen G. 2007. Increased Website Popularity through Compliance with Usability Guidelines. A Doctoral Dissertation. University of Otago, New Zealand.
- Serhat, A. and K. Cengiz. 2012, Evaluation of e-commerce website quality using fuzzy multi-criteria decision making approach. *IAENG International Journal of Computer Science* 39: 69-70.
- Shlens, J. A. 2006. Tutorial on principal component analysis: derivation, discussion and singular value decomposition. [Online] Available from: <http://www.snl.salk.edu/~shlens/notes.html>. (accessed 11.02.08)
- Statestia, The Statistics Portal. 2015. Global number of internet users 2005-2015, [Online] Available from: <http://www.statista.com/statistics/273018/number-of-internet-users-worldwide/>
- Woolrych, A., K. Hornbæk, E. Frøkjær, and G. Cockton. 2011. Ingredients and Meals rather than Recipes: A Proposal for Research that does not treat Usability Evaluation Methods as Indivisible Wholes. *International Journal of Human-Computer Interaction* 27 (10): 940-970.
- Younghwa L. and A. K. Kenneth. 2006. Investigating the effect of website quality on e-business success: an analytic hierarchy process (AHP) approach. *Decision support systems* 42 (3): 1383-1401.
- Zahedi, Sh. 2010. Website Quality Assessment Tools and Measures. *Journal of Management Development and Evolution* 4: 16-5 (in Persian).

Zahran, D. I., H. A. Al-Nuaim, M. J. Rutter, and D. Benyon. 2014. A Comparative Approach to Web Evaluation and Website Evaluation Methods. *International Journal of Public Information Systems* 10 (1): 21-39.

Zhang Y., H. Cui, J. Burkell and R. E. Mercer. 2014. A Machine Learning Approach for Rating the Quality of Depression Treatment Web Pages, conferences 2014, PP. 192-212.

مولود آرمان

متولد سال ۱۳۶۶، دارای مدرک تحصیلی کارشناسی ارشد در رشته مدیریت فناوری اطلاعات از دانشگاه تهران است. ایشان هم‌اکنون پژوهشگر فناوری اطلاعات در مرکز تحقیقات مخابرات ایران است. مدیریت اطلاعات، تحلیل داده و کسب و کار هوشمند از جمله علایق پژوهشی وی است.



بابک سه رابی پور تچی

متولد سال ۱۳۴۶، دارای مدرک تحصیلی دکتری در رشته علم مدیریت از دانشگاه لنگستن انگلستان است. ایشان هم‌اکنون استاد گروه مدیریت فناوری اطلاعات دانشگاه تهران و رئیس آموزش‌های الکترونیک دانشگاه تهران است. مدیریت منابع اطلاعاتی، کسب و کار هوشمند، یادگیری الکترونیکی و کلان‌داده‌ها از جمله علایق پژوهشی وی است.



امیر مانیان

دارای مدرک تحصیلی دکتری در رشته مدیریت بازارگانی از دانشگاه تهران است. ایشان هم‌اکنون دانشیار گروه مدیریت فناوری اطلاعات دانشگاه تهران است.

تجارت الکترونیک، مبانی فلسفی سیستم‌های اطلاعاتی و سیستم‌های اطلاعاتی مدیریت از جمله علایق پژوهشی وی است.

