

تصحیح خودکار غلط‌های تایپی فارسی به کمک شبکه عصبی مصنوعی

ترکیبی

رسول دژکام^۳

رضا صفابخشش^۲

امیرشہاب شاھمیری^۱

۱- دانشآموخته کارشناسی ارشد دانشکده مهندسی کامپیوتر- دانشگاه صنعتی امیرکبیر - تهران- ایران
amir@shahmiri.ir

۲- استاد دانشکده مهندسی کامپیوتر- دانشگاه صنعتی امیرکبیر- تهران- ایران
safa@ce.aut.ac.ir

۳- دانشآموخته کارشناسی ارشد دانشکده مهندسی کامپیوتر- دانشگاه صنعتی امیرکبیر- تهران- ایران
dezhkam@ce.aut.ac.ir

چکیده: ارایه راهی برای تصحیح غلط‌های املایی نگاشته شده توسط انسان یکی از اهداف مورد توجه در دانش هوش مصنوعی، متن کاوی و پردازش زبان طبیعی است. بیشتر روش‌های موجود برای تصحیح غلط‌های املایی بر پایه الگوریتم‌های جستجو در فرهنگ واژگان و تعیین نسبت شباهت واژگان درست موجود در فرهنگ واژگان با واژه نادرست مورد نظر کار می‌کنند.

در این پژوهش طراحی، پیاده‌سازی و ارزیابی یک مصحح املایی به کمک شبکه‌های عصبی مصنوعی هاپفیلد و پرسپترون چند لایه با رویکرد ویژه به غلط‌های تایپی کاربر ارایه می‌شود. نتایج به دست آمده نشان می‌دهند که برای یادگیری واژه‌نامه‌ای مشتمل بر ۴ تا ۶ واژه ۴ تا ۶ حرفی و تصحیح غلط‌های مربوط به آنها، شبکه هاپفیلد به دقیقی بین ۵۵٪ و ۱۰۰٪ درستی و شبکه پرسپترون چند لایه - که در این تحقیق عمل یادگیری را در قالب دسته‌بندی انجام می‌دهد - به دقیقی بین ۸۰٪ و ۱۰۰٪ درستی دست یافته، که این مقدار با به کارگیری شبکه‌های ترکیبی به نزدیک به ۸۰٪ دقت درستی برای بیش از ۳۰۰۰ واژه افزایش یافته است.

واژه‌های کلیدی: صحیح خودکار غلط تایپی فارسی، غلط املایی، شبکه عصبی مصنوعی هاپفیلد، پرسپترون چند لایه، فاصله کلید.

تاریخ ارسال: مقاله : ۱۳۸۶/۸/۴

تاریخ پذیرش مقاله : ۱۳۸۷/۱۰/۲

نام نویسنده‌ی مسئول : رضا صفابخشش

نشانی نویسنده‌ی مسئول : ایران - تهران - خیابان حافظ - پلاک ۴۲۴ - دانشگاه صنعتی امیر کبیر - دانشکده مهندسی کامپیوتر و فناوری اطلاعات

۱- مقدمه

دسته تقسیم کرد^[۴]:
غلط تایپی^۸، که چهار گروه اصلی درج حرف اضافه^۹، حذف حرف^{۱۰}، نگارش یک حرف اشتباه به جای حرف اصلی^{۱۱} و جابه‌جایی دو حرف همسایه^{۱۲} را در بر دارد^[۳و۵]. این چهار گونه، نزدیک به ۸۰٪ خطاهای تایپی را در بر می‌گیرند^[۶].
غلط املایی^{۱۳}، که ناشی از ضعف دانش زبانی نویسنده در تشخیص اصوات واژه و شیوه نگارش آن است.
خطای انتقال^{۱۴}، که در هنگام انتقال اطلاعات بر شبکه یا دیسک و بازناسی نوری حروف^{۱۵} رخ می‌دهد.

برای پیاده‌سازی یک سیستم مصحح املایی، دو کار اصلی باید انجام پذیرد: نخست باید واژه مورد نظر در فرهنگ واژگان جستجو شود تا در صورت موجود نبودن غلط قلمداد گردد؛ سپس با استفاده از روش‌های گوناگون در حالت خودکار^{۱۶} یک، یا در حالت محاوره‌ای^{۱۷} چند واژه به عنوان حایگرین پیشنهاد گردد^[۷]. از آنجا که بسیاری از واژگان با تغییر یک حرف به واژه‌ای دیگر تبدیل می‌شوند، هیچگاه نمی‌توان انتظار داشت که دقت تصحیح لغوی^{۱۸} به صدرصد برسد و دستیابی بهترین روش‌های مصحح به این دقت نیز در عمل - حتی با توجه به درک مفهوم جملات بر پایه روش‌های پردازش زبان طبیعی - برای تصحیح تمامی واژگان یک زبان امکان ناپذیر خواهد بود. گذشته از این، با توجه به این که بیشتر روش‌های تصحیح غلط بر روی تنها یک خط اوایه خوب کار می‌کنند، تا زمانی که روش‌های تصحیح خطاهای ترکیبی مانند جابه‌جایی رشته^{۱۹} و وارونه نویسی^{۲۰} به میان نیایند، نمی‌توان به آنها اطمینان چندانی داشت^[۴]. از این‌رو به نظر می‌رسد که دقت درستی ۹۰٪ برای یک مصحح خودکار مطلوب باشد؛ در حالی که این مقدار برای انسان ۷۵٪ است^[۸]. از این‌رو این‌گونه غلطها به ندرت در گروه واژگان آزمایشی جای می‌گیرند^[۵و۶].
اغلب روش‌هایی که تاکنون برای تصحیح لغوی ارایه شده‌اند، تطبیق رشته حروف^{۲۱} واژه غلط^{۲۲} را - که در فرهنگ واژگان موجود نیست - با نزدیکترین واژه در فرهنگ واژگان، بر پایه فاصله ویرایشی^{۲۳}، فاصله همینگ^{۲۴} یا فاصله لونشتین^{۲۵} به کار می‌گیرند و یک یا چند واژه جایگزین را پیشنهاد می‌دهند^[۳-۹]. این فاصله ویرایشی بنا بر اختلافات تک‌تک حروف واژه غلط با کلمات فرهنگ واژگان به دست می‌آید و این‌رو اغلب - به‌ویژه در هنگام ویرایش واژگان کم حرف - نتیجه دلخواهی به‌هرماه ندارد. برای نمونه، اگر به جای واژه "word" رشته "wprd" تایپ شود، این روش ۷۱۰ واژه جایگزین هم‌سطح را پیشنهاد می‌دهد^[۵].

هدف این پژوهش ارایه روشی جدید برای ویرایش لغوی متون با رویکرد ویژه به غلط‌های تایپی است. دلیل این انتخاب آن بوده که متونی که توسط کاربر تایپ می‌شوند، خود پیشتر توسط نویسنده (که ممکن است خود کاربر باشد) و با آگاهی وی از ساختار جملات و به‌ویژه مفهوم آنها شکل گرفته‌اند و بنابراین نیاز چندانی به ویرایش دستوری و مفهومی ندارند و حتی ممکن است به‌دلایل ویژه، به‌عمد

گفت‌وگوی معنی‌دار میان انسان و ماشین یکی از آرزوهای دانشمندان علوم رایانه و یکی از مباحثت مورد توجه در زمینه هوش مصنوعی است. در این زمینه، درک جمله بیان شده توسط انسان به‌زبان طبیعی از سوی ماشین و نیز تولید جمله درست و با معنی توسط ماشین، از مهم‌ترین اهداف علوم پردازش و فهم زبان طبیعی^۱ و هوش مصنوعی است که هرچند تاکنون به موقوفیت‌های چشمگیری دست نیافته، اما افق‌های روشی را پیش روی پژوهشگران این عرصه قرار داده است.

مساله مشابه دیگری که محققان هوش مصنوعی و متن‌کاوی^۲ بدان توجه دارند، ویرایش یا درک متن نوشته شده به‌دست انسان، توسط ماشین است که معمولاً سه گام زیر را در بر می‌گیرد^[۱]:
ویرایش لغوی^۳: که در آن کوشش می‌شود تا اشتباهات دستوری نگارش املایی یک واژه، جایگزین مناسبی به کمک یک پایگاه داده جامع از واژگان برای آن پیدا شود. برای نمونه به جای واژه "ویرایش" واژه "ویرایش" پیشنهاد گردد.

ویرایش دستوری^۴: که در آن کوشش می‌شود تا اشتباهات دستوری جملات شناسایی و تصحیح گردد. برای نمونه، رخداد زمانی میان فعل و قید جمله "دیروز من و او یکدیگر را دید." کشف گردد و جمله‌ای مانند "دیروز من و او یکدیگر را دیدیم." پیشنهاد گردد. این امر به کمک مجموعه قواعد دستورزبانی و روش‌های گوناگون تجزیه واژگان جمله در مبحث پردازش و فهم زبان طبیعی به نتایجی رضایت‌بخش رسیده است.

ویرایش مفهومی^۵: که در آن کوشش می‌شود تا به رغم درستی ساختار جمله از نظر دستورزبان، ناهمانگی‌های مفهومی آن دست‌کم شناخته و تا جای ممکن تصحیح گردد. برای نمونه جمله "میز هواپیما را خورد." از دیدگاه املایی و دستوری اشتباهی ندارد، اما مفهوم درستی از آن بر نمی‌آید.

روشن است که در هر گونه پردازش متن نخستین گام، تصحیح غلط‌های واژگان متن است. غلط‌های واژه‌ای یک متن به دو دسته تقسیم می‌شوند: یکی آن که واژه مورد نظر در واژه‌نامه موجود است، اما به‌دلیل ضعف دانش زبانی نگارنده با اشتباه وی، با توجه به مفهوم جمله نابه‌جا نوشته شده است (مانند واژه "عرب" در جمله "من در این شهر قربت هستم"). این گونه خطاهای در زبان فارسی کمیاب است و بیشتر در واژه‌های دخیل از زبان‌های دیگر، به‌ویژه زبان عربی، رخ می‌دهد و در زبان‌های غیرآوایی مانند انگلیسی نیز بسیار دیده می‌شود (مانند "piece" در "a peace of cake"^[۲]). این دسته از اشتباهات از جمله خطاهای ابهام گرامری^۶ و تشابه آوایی^۷ هستند^[۳] و در محدوده این پژوهش نمی‌گنجند، زیرا تنها با تحلیل معنا و مفهوم جمله می‌توان آنها را کشف کرد. دسته دوم غلط‌ها نیز واژگانی هستند که در واژه‌نامه موجود نیستند و از این‌رو غلط به‌شمار می‌آیند. به‌طور کلی خطاهای متون و مستندات را می‌توان به سه



شناخت و ترکیب روش‌های مبتنی بر فاصله واژگان برای انواع خطاهای احتمالی در متن، تعاریفی سیستماتیک را همراه با الگوریتم‌های تصحیح ارایه دهنده [۷].

۱-۲- ویژگی‌های مساله

در مساله غلط‌های املایی، احتمال پیش آمدن غلط تایپی ناشی از اشتباه کاربر، بیشتر از غلط‌های املایی متأثر از ضعف دانش زبانی نویسنده اصلی است؛ زیرا معمول تر آن است که فرض کنیم، کسی که خود متنی را به کمک رایانه تایپ می‌کند یا آنرا به حروفچین می‌سپارد، به اندازه‌ای تسلط بر واژگان دارد که غلط‌های املایی متن وی ناچیز باشد، اما از سوی دیگر رخداد غلط تایپی امری رایج در هنگام ماشینی کردن متون است. این دو گونه اشتباه، ماهیتی متفاوت دارند و شناخت و استفاده از ویژگی‌های آنها می‌تواند به ما در تصحیح املایی متون کمک کند. این نکته مساله‌ای است که در روش‌های کلاسیک و نرم‌افزارهای تجاری تصحیح غلط املایی - که اغلب بر پایه الگوریتم‌های جستجو و استوارند - بدان توجه چندانی نشده و از این‌رو یکی از امتیازات این تحقیق بهشمار می‌رود. البته باید در نظر داشت که نرم‌افزارهای تجاری از آن‌رو بر پایه روش‌های جستجو در فرهنگ واژگان^۴ کار می‌کنند که هدف آنها دستیابی سریع به پاسخ با کمترین حافظه مصرفی است؛ در حالی که روش‌های آکادمیک بیشتر به دستیابی به بهترین پاسخ می‌اندیشند [۴].

از آنجا که جستجو در پایگاه داده‌ای با چند صد هزار واژه کاری وقت‌گیر است، روش‌های تصحیح غلط املایی چهار راهبرد اساسی را برای کاهش تعداد جستجوها به کار می‌گیرند که آنها را روش‌های تطبیق کامل^۵ می‌نامند [۴]:

بر پایه تعداد دفعات تکرار؛ بدین ترتیب که واژگانی که بیشترین مورد استفاده را در متون دارند، در یک فرهنگ واژگان کوچکتر گردآوری شده، مصحح در هنگام یافتن غلط، نخست این پایگاه را می‌جوید و در صورتی که واژه یافته نشد، پایگاه‌های واژگان کم‌استفاده‌تر در اولویت‌های بعدی را نیز ارزیابی می‌کند.

بر پایه طول واژه؛ فرهنگ واژگان به فرهنگ‌های ۲ تا n حرفی بخش می‌شود و در هنگام برخورد با واژه غلط k حرفی، نخست فرهنگ k حرفی و سپس در صورت نیافتن واژه صحیح، فرهنگ‌های $k+1$ و $k-1$ حرفی جستجو می‌گردد.

بر پایه نخستین حرف واژه‌نامه با ساختار درختی؛ در این ساختار، ریشه به تعداد حروف خط زبان مورد نظر (انگلیسی ۲۶ و فارسی ۳۲) گره دارد و هر گره نیز فرزندانی تا همین تعداد دارد. بنابراین برای یافتن واژه k حرفی به k جستجو نیاز است. اما روش است که این روش زمانی خوب کار می‌کند که حروف آغازین واژه درست نگاشته شده باشند.

بر پایه فشرده‌سازی فرهنگ واژگان؛ با منظور کردن این نکته که بسیاری از واژگان یک زبان ریشه‌ای مشترک دارند، می‌توان فرهنگ را به این واژگان ریشه‌ای محدود ساخت و در عوض قوانینی برای تولید واژگان

نکاتی در آنها درج شده باشد که از دیدگاه دستوری یا مفهومی اشتباه به نظر برسد و بنابراین اعمال تغییرات بر آنها خود موجب پیش آمدن اشتباهات بیشتر گردد. از سوی دیگر، با افزایش سواد و دانش عمومی و نیز با گسترش کاربرد رایانه در جهان، امروزه دیگر مشکل غلط املایی رو به کاهش و در عوض غلط تایپی رو به افزایش است.

۱-۱- پیشینهٔ پژوهش

"فوروگوری" در سال ۱۹۹۰ با توجه به تفاوت ماهیت غلط‌های املایی انگلیسی غیرانگلیسی‌زبانان و با بررسی تفاوت‌های آوای زبان ژاپنی و انگلیسی، سیستمی کمکی برای تصحیح غلط‌های املایی ژاپنی‌ها در هنگام نگارش به‌زبان انگلیسی پیشنهاد کرد که می‌توانست دقت نرم‌افزار تصحیح املایی کرکت‌استار^۶ را از ۶۰٪ به ۷۵٪ برساند [۱۰]. در سال ۱۹۹۶ "شانگ" و "مرتال" با بررسی چند الگوریتم دیگر، روش ترای^۷ را برای تخمین نزدیکی دو رشته حروف بهمود و گسترش دادند [۱۱]. "لاونیه" در سال ۱۹۹۲ توانست روش‌های در قالب آرایه‌ای ۲-بعدی از ۶۹ پردازنده را به‌همراه یک تکنیک برنامه‌نویسی پویا برای تصحیح مقایسه‌ای رشته حروف بسازد که می‌توانست ۲۰۰ هزار واژه را در هر ثانیه تصحیح کند [۶]. "چاودوری" در سال ۲۰۰۲ با توجه به ویژگی‌های آوایی و غیرآوایی زبان هندی و با به کارگیری برخی از تکنیک‌ها - مانند روش n -گرام^۸ - توانست سیستم مصحح املایی برای زبان هندی و بنگالایی^۹ ارایه کند که به دقت درستی ۹۵٪ دست یافت [۱۲]. در سال ۲۰۰۰ "هاج" و "اوستین" توانستند با ترکیب روش n -گرام و رویکرد فاصله همینگ سیستمی را فراهم آورند که برای یک پایگاه با تعداد محدودی از واژگان و با سرعتی قابل قبول، هر چهار گونه از غلط املایی را با دقتی تا ۹۷٪ تصحیح کند که به طور متوسط ۸ واژه جایگزین را پیشنهاد می‌کرد [۵]. در سال ۲۰۰۰ "الی" و همکارانش توانستند یک روش تطابق تخمینی واژه فازی^{۱۰} را در قالب مصحح املایی اختصاصی برای زبان چینی ارایه کنند که علاوه بر غلط‌های رایج، جایه‌جایی رشته را نیز تصحیح می‌کرد [۱۲]. "راش"^{۱۱} و همکارانش در سال ۲۰۰۱ توانستند با ترکیبی از روش‌ها - مانند تطابق رشته به رشته و مدل مخفی مارکف - در تصحیح واژگان متون پژشکی به دقت درستی ۹۸٪ دست یابند [۲۰]. "هوانگ" و "پاورز" در سال ۲۰۰۲ با ترکیبی از روش‌ها و با در نظر گرفتن برخی غلط‌های تایپی توانستند در متون حجیم به دقت تصحیح ۷۴٪ دست یابند [۱۴].

"چرکاسکی"^{۱۲} و همکارانش در سال ۱۹۹۰ توانستند با ترکیب برخی از شبکه‌های عصبی یادآور^{۱۳} مانند شبکه هاپفیلد^{۱۴} و شبکه‌های پس‌انتشار^{۱۵} با دیگر روش‌ها، سیستم غلط‌یاب املایی برای واژگان کوتاه (۵ تا ۷ حرفی) و بلند (۱۰ تا ۱۲ حرفی) با تعداد گره‌های ورودی برابر با توانی از ۲۶ (به تعداد حروف الفبای انگلیسی) به مقدار n در الگوریتم n -گرام و گره‌های خروجی به تعداد واژه‌های ذخیره شده، بسازند و به دقت ۱۵ تا ۱۰۰ درصد برای انواع خطأ و مقدادر n دست یابند [۴]. "گارفینکل"^{۱۶} و همکارانش در سال ۲۰۰۲ کوشیدند تا با

۱-۲- غلط املایی در زبان فارسی

غلط املایی در زبان فارسی معمولاً به دو شکل پیش می‌آید: یکی این که نگارنده یکی از حروف هم صدا را به جای دیگری به کار برده. این گونه اشتباه معمولاً در مورد واژه‌های عربی دخیل در فارسی رخ می‌دهد. برای نمونه نویسنده ممکن است در واژه "اضطرار حرف "ض" را با "ز"، "ذ" یا "ظ" و حرف "ط" را با "ت" اشتباه بگیرد و واژه "تفريظ" را "تغريظ"، "تفريض" یا بهشيوه‌های ديگر بنگارد. اين اشتباه عموماً در مورد واژه‌های هم آوا در خط فارسی مانند "ت: ط"، "ح: ه"، "ز: ذ: ض: ظ"، "ق: غ" و گاهی نيز "ا: ع" (مانند مواخذه : مواخذه) رخ می‌دهد.

دوم اشتباه در نگارش حروف صدادار (مصطفوت) یا آوای واژگان است که آن هم بیشتر در مورد واژگان دخیل از زبان‌های اروپایی - مانند انگلیسی و فرانسه - و نیز زبان عربی رخ می‌رهد. برای نمونه برای واژگان "Glass"، "Flat" و "Float" دو نگارش "فلت" و "فلوت" را به کار می‌برند یا واژه "Robot" را "ربات"، "روبات" و یا "ربوت" و یا "مسئله" از عربی را "مساله"، "مساله" یا بهشيوه‌های ديگر می‌نویسند. هر دوی این اشتباهات اغلب برای نویسنده‌گان کم سن و سال (تا مقطع دبستان و راهنمایی) پیش می‌آید و با افزایش سن و تجربه کم کم از بین می‌رود.

۲-۲- غلط تایپی در زبان فارسی

اما غلط تایپی به سواد نویسنده بستگی ندارد، بلکه وابسته به مهارت و دقت حروف‌چین و موقعیت کلیدهای صفحه کلید است. شکل ۱، سه نمونه از موقعیت‌های حروف بر انواع صفحه کلید را نشان می‌دهد. بخشی از این ناهمگونی‌ها به دلیل تغییرات پیاپی در استانداردها و تعداد دکمه‌های صفحه کلید رخ داده و بخشی دیگر، به علت نبود اتفاق نظر میان استانداردگذاران درون و حتی بیرون از کشور بر سر تعیین جایگاه حروف فارسی بر دکمه‌ها پدید آمده و این ناهمانگی‌ها موجب افزایش خطاهای تایپی میان کاربران فارسی‌زبان گشته است.

در این زمینه برای شناخت بهتر ماهیت غلط تایپی فارسی با چند فرد خبره در حروف‌چینی گفت‌وگو شد و اطلاعات آنان به شکل زیر طبقه‌بندی گردید:

- اشتباه در تایپ یک واژه، معمولاً بین کلیدهای همسایه رخ می‌دهد. مانند: "ج" و "ح"، "ن" و "ت" یا "ی" و "س".
- اشتباه تایپی اغلب بین کلیدهای یک سطر از صفحه کلید رخ می‌دهد و اشتباه با کلیدهای سطر بالا یا پایین کم پیش می‌آید. برای نمونه حرف "ه" با "خ" یا "ع" اشتباه گرفته می‌شود، اما اشتباه آن با "ت" یا "ن" که در همسایگی سطر پایین تر قرار دارد، بسیار کمیاب است.
- به دلیل استاندارد نبودن جای برخی از حروف بر صفحه کلید، برخی از حروف که نه شباهت آوایی با هم دارند و نه همسایه نزدیک یکدیگر هستند، با هم اشتباه می‌شوند. مانند "پ" و "ژ".

ممکن بدان افزود. روش فشرده‌سازی فرنگ، به دلیل ویژگی‌های واژه‌سازی زبانی، در زبان عربی بهتر از فارسی و انگلیسی کار خواهد کرد.

در مجموع می‌توان ویژگی‌های روش‌های تصحیح کلاسیک مبتنی بر جست‌وجو و مبتنی بر شبکه عصبی را چنین بیان کرد:

- با وجود این که شبکه عصبی در فاز یادگیری به زمان بالای نیاز دارد، اما در فاز آزمایش به سرعت نتیجه می‌گیرد و بنابراین از هر روش دیگری سریع‌تر است.

• شبکه‌های عصبی مصنوعی طرفیتی محدود دارند؛ در نتیجه برای یادگیری تعداد زیادی واژه که بتواند حداقل نیاز برای مصحح املایی را برآورده سازد، با مشکل کاهش دقت روبرو می‌شوند.

یافتن بهترین شبکه با تعداد لایه و نرون، خود مسائلهای نسبی و تجربی است و تصمیم‌گیری در مورد آن دقیق نیست. از این رو مساله باید با شبکه‌های گوناگون آزموده شود، تا بهترین ترکیب به دست آید.

• با بهتر شدن و پیدایش انواع تازه و پرتوان تر شبکه‌های عصبی در آینده، نتایج کار نیز بهبود خواهد یافت.

در شبکه‌های عصبی با ساختار و طراحی ساده، با ورود یک واژه (درست یا نادرست) خروجی در نهایت یک واژه است، اما در روش‌های کلاسیک می‌توان بنا بر نسبت شباهت واژه نادرست به واژگان درست در فرنگ واژگان، تعدادی واژه جایگزین پیشنهاد کرد.

• در صورتی که واژه‌ای بدون بررسی درست یا نادرست بودنش (بنا بر بود یا نبود آن واژه در فرنگ واژگان) به شبکه عصبی وارد گردد، به دلیل ماهیت شبکه‌های عصبی که همواره درصدی از خطای را به همراه دارد، ممکن است که واژه درست هم به واژه‌ای نادرست نگاشت شود.

در ادامه این مقاله نخست در بخش ۲ به تعریف و شناخت ماهیت غلط تایپی می‌پردازیم و تفاوت‌های آن با غلط املایی در زبان فارسی را بررسی خواهیم کرد. سپس در بخش ۳ به روش‌های ارایه شده برای تصحیح این اشتباهات خواهیم پرداخت و پس از آن در بخش ۴ نتایج تصحیح را بررسی خواهیم نمود و سرانجام در بخش ۵ مزایا و معایب جمع‌بندی و اهداف آینده بیان خواهد شد.

۲- غلط تایپی

همان‌گونه که در مقدمه گفته شد، در هنگام مواجهه با غلط‌های املایی، بهتر است فرض کنیم که غلط موجود ناشی از اشتباه تایپی بوده است و نه ضعف دانش زبانی نویسنده؛ زیرا کسی که متنی را به کمک رایانه تایپ می‌کند یا آن را به حروف‌چین می‌سپارد، به اندازه کافی بر زبان و واژگانش آشنایی دارد که غلط‌های املایی متن وی ناچیز باشد، اما از سوی دیگر رخداد غلط تایپی در هنگام تایپ متن بسیار رایج است.



'	1	2	3	4	5	6	7	8	9	0	-	=	Back Space
Tab	Q	ص	W	ث	E	ق	R	ف	T	غ	Y	ع	U
Caps Lock	ش	A	S	س	د	پ	F	ل	G	ا	H	ت	J
Shift	Z	ظ	X	ز	C	ر	V	ذ	B	د	N	ئ	M
												,	.
												/	/
												Shift	\
'	1	2	3	4	5	6	7	8	9	0	-	=	Back Space
Tab	Q	ص	W	ث	E	ق	R	ف	T	غ	Y	ع	U
Caps Lock	ش	A	S	س	د	پ	F	ل	G	ا	H	ت	J
Shift	ظ	Z	X	ز	C	ر	V	ذ	B	د	N	ئ	M
												,	.
												/	/
												Shift	\
'	1	2	3	4	5	6	7	8	9	0	-	=	Back
Tab	Q	ص	W	ث	E	ق	R	ف	T	غ	Y	ع	U
Caps Lock	ش	A	S	س	د	پ	F	ل	G	ا	H	ت	J
Shift	ظ	Z	X	ز	C	ر	V	ذ	B	د	N	ئ	M
												,	.
												/	/
												Shift	\

شکل (۱): سه نمونه از جانشانی حروف فارسی بر صفحه کلید.

جایه‌جایی کلید: به جای یکی از حروف اصلی، یکی از کلیدهای دیگر بر صفحه کلید فشرده می‌شود. کلید اشتباه اغلب نزدیک به کلید اصلی است. مانند: "کیومرث" : کبومرث / گیومرث".

انتقال کلید: یکی از حروف اصلی، با حرف همسایه یا چند حرف قبل یا بعدی جایه‌جا تایپ می‌شود. مانند: "کیومرث" : کویمرث / کومریث". غلط املایی (جایه‌جایی ویژه): به جای یکی از حروف اصلی، یکی از دیگر کلیدهای صفحه کلید فشرده می‌شود؛ به گونه‌ای که در زبان فارسی آن حرف با حرف اصلی هم صداست مانند: "کیومرث" : کیومرس". این گونه غلط ناشی از ضعف دانش زبانی حروف‌چین است و بسیار کم رخ می‌دهد، زیرا متن اصلی پیش روی حروف‌چین است.

فاصله اضافه: یک کاراکتر فاصله نابه‌جا درج می‌گردد. مانند: "کیومرث" : کی و مرث". این غلط به‌ویژه در برخی حالت‌های ویژه مانند "ها" ای جمع و "می" استمرار و اغلب به‌جای فاصله مجازی^{۳۶} (کوتاه) رخ می‌دهد. مانند: "واژه‌ها" : واژه ها" و "می‌رود" : می رود". این غلط

گونه‌ای ویژه از غلط‌های درج است. فاصله کم: کاراکتر فاصله میان دو واژه جداگانه درج نمی‌گردد. مانند: "کیومرث سیامک" : کیومرث‌سیامک". این غلط گونه‌ای ویژه از غلط‌های حذف است.

بر این پایه با نمونه‌برداری و تخمین آماری غلط‌های تایپی زبان فارسی در هنگام کار حروف‌چین خبره به شرح جدول ۱ به دست آمد. برای بررسی صحت و سقم هر یک از موارد این جدول از هر یک از افراد خواسته شد تا متنی را بدون استفاده از کلید بازگشت^{۳۸} در هنگام

ارتباطی ناچیز هم در اشتباه بین حروف هم‌صدا وجود دارد.^{۳۶} مانند: "ض" و "ظ" یا "غ" و "ق".

گاه در حروفی که نیاز به فشردن کلید شیفت دارند، آن حرف با حرف اصلی جایه‌جا می‌شود. مانند "ا" به جای "آ" (که البته این مورد غلط املایی به‌شمار نمی‌رود)، یا "ی" و "ط"، "ز" به جای "ژ" (در برخی از صفحه کلیدها) و "ی"، "س" و "ش" به جای هر یک از اعراب.

گاه دو حرف از یک واژه جایه‌جا تایپ می‌شود، مانند: "زیبا" : زیبا.

این اتفاق نیز بیشتر در مورد حروف همسایه رخ می‌دهد. گاه غلط املایی بدین شکل رخ می‌دهد که یکی از حروف واژه زده نمی‌شود یا یکی از کلیدهای جانی یا خود کلید یکی از حروف واژه، اضافه زده می‌شود. مانند: "هشدار" : هششدار : هشار".

از این رو انواع غلط‌های تایپی زبان فارسی به‌شرح زیر دسته‌بندی شد:

درج حرف: در هنگام نگارش، یک حرف اضافه به‌اشتباه تایپ می‌شود. مانند: "کیومرث" : کیونمرث".

تکرار حرف (درج حرف همسایه): یعنی در هنگام نگارش، یکی از حروف اصلی به‌اشتباه دو بار تایپ می‌شود. مانند: "کیومرث" : کیوممرث". این گونه غلط خود نوعی درج حرف است که بیش از گونه‌های دیگر رخ می‌دهد.

حذف حرف: در هنگام نگارش، یکی از حروف اصلی تایپ نمی‌شود. مانند: "کیومرث" : کیمرث".

"*holy*" در اینجا "y" به جای "j" آمده در صورتی که این دو حرف در دو سطر جدا قرار دارند و احتمال اشتباه تایپی این دو به دلیل دوری از هم بسیار ناچیز است.

همان‌گونه که مشاهده می‌شود، در این نرمافزار واژه "*golf*" اصلاً پیشنهاد نشده و بهترین پیشنهاد در اولویت سوم قرار دارد.

به عنوان نمونه‌ای دیگر، در صورتی که کاربر بخواهد واژه "*sear*" را تایپ کند، اما به اشتباه به جای حرف "d"، حرف کناری آن یعنی "a" و بنابراین "*aear*" را تایپ کند، نرمافزار ورد واژگان زیر را به ترتیب اولویت پیشنهاد می‌دهد:

: در اینجا نرمافزار، حرف "r" دو خانه به عقب برد و فرض کرده که کاربر جای آن را دو خانه جایه‌جا تایپ کرده که البته این اشتباه چندان محتمل نیست.

: در اینجا فرض شده که کاربر به جای حرف "i" دو حرف "ea"

را باشتباه تایپ کرده و البته این اشتباه هم چندان منطقی نیست.

: در اینجا "j" به جای "e" آمده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو، به دلیل دوری از هم، ناچیز است.

: در اینجا هم مانند مورد قبلی حرف "j" به جای "e" آمده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو اندک است.

: باز هم در اینجا حرف "g" به جای "e" آمده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو کم است.

همان‌گونه که دیده می‌شود، در این نرمافزار واژه "*sear*" که منطقی‌ترین گزینه است، اصلاً پیشنهاد نشده و بهترین پیشنهاد در رده سوم قرار دارد.

اکنون نمونه‌ای دیگر را در نظر گیرید: اگر کاربر بخواهد واژه "*that*" را تایپ کن، اما به اشتباه به جای حرف "t" دوم، حرف کناری آن یعنی "y" و بنابراین "*thay*" را تایپ کند، نرمافزار ورد واژگان زیر را به ترتیب اولویت پیشنهاد می‌دهد:

: در اینجا "e" به جای "a" آمده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو ناچیز است.

: در این مورد فرض شده که کاربر به جای حرف "e"، باشتباه دو حرف "ay" را تایپ کرده که امری بسیار بعيد است.

: در اینجا فرض شده که به جای حرف "t"، حرف "h" تایپ شده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو اندک است.

: در اینجا "t" به جای "y" آمده و این دو حرف بر کلیدهای مجاور قرار دارند و این انتخاب معقول‌تر به نظر می‌رسد.

: در این مورد هم "w" به جای "y" آمده، در صورتی که این دو حرف در همسایگی دوری نسبت به هم جای دارند و احتمال اشتباه تایپی این دو کم است.

رخداد خطأ، تایپ کنند. نتایج به دست آمده در تایید موارد فوق بود و خلاف آن را نشان نمی‌داد.

جدول (۱): انواع غلط‌های تایپی و نسبت رخداد آنها در زبان فارسی.

ردیف	نوع غلط	گونه اصلی	درصد
۱	درج حرف	درج	۸
۲	تکرار حرف	درج	۱۴/۵
۳	حذف حرف	حذف	۱۹
۴	جایه‌جایی کلید	جایه‌جایی	۳۹/۵
۵	انتقال کلید	انتقال	۵
۶	غلط املایی	جایه‌جایی	۰/۵
۷	فاصله افزوده	درج	۲/۵
۸	فاصله کم	حذف	۵
۹	موارد دیگر	ترکیبی	۶/۵
۱۰	نسبت حروف غلط به حروف درست	-	۱/۹۵
۱۱	نسبت واژگان غلط به واژگان درست	-	۵/۳۱

۳-۲- تصحیح املایی بر پایه فاصله

امروزه بیشتر نرمافزارهای مصحح غلط املایی که به صورت تجاری در بازار ارایه می‌شوند، بر پایه فاصله (ویرایشی، همینگ، لونشتن و ...) کار می‌کنند، که البته در بسیاری از موارد - به ویژه در هنگام رخداد غلط‌های جایه‌جایی - نتیجه دلچسی به همراه ندارند. در این میان، مصحح املایی نرمافزار ورد از شرکت مایکروسافت^۹ یکی از کارآمدترین و پرطرفدارترین تصحیح‌کننده‌های املایی متن را ارایه کرده است. با وجود آن که این نرمافزار خود برای تایپ و صفحه‌بندی طراحی شده، به غلط تایپی توجهی ندارد، بلکه احتمالاً با توجه به پایگاه داده، تک‌تک واژگان تایپ شده را با آن پایگاه داده می‌سنجد و در صورتی که آن وجود در پایگاه موجود نباشد، آن را مشخص کرده و به کمک برخی قوانین کلاسیک برای یافتن نزدیکترین واژه، چند واژه را به ترتیب اولویت از روی سازگاری به کاربر پیشنهاد می‌دهد.

برای نمونه، در صورتی که کاربر بخواهد واژه "*golf*" را تایپ کند، اما به اشتباه به جای حرف "g"، حرف کناری آن "h" و بنابراین "*holf*" را تایپ کند، نرمافزار ورد واژگان زیر را به ترتیب پیشنهاد می‌دهد:

: در اینجا "a" به جای "o" آمده در صورتی که احتمال اشتباه تایپی این دو به دلیل دوری از هم بسیار ناچیز است.

: در اینجا "o" به جای "l" آمده در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو به دلیل دوری از هم بسیار ناچیز است.

: در اینجا "d" به جای "j" آمده و این دو حرف بر کلیدهای مجاور قرار دارند و این انتخاب معقول‌تر به نظر می‌رسد.

: در این مورد هم "e" به جای "j" آمده، در صورتی که این دو حرف در دو سطر جدا قراردارند و احتمال اشتباه تایپی این دو ناچیز است.



ض	ص	ث	ق	ف	غ	ع	ه	خ	ح	ج	ج
1F00	0F00	0700	0300	0100	0000	0040	00C0	00E0	00F0	00F8	00FC
ش	س	ى	ب	ل	ا	ت	ن	م	ك	گ	
9F01	8F01	8701	8301	8101	8001	8041	80C1	80E1	80F1	80F9	
ظ	ط	ز	ر	ذ	د	ئ	و		پ	ڙ	
DF03	CF03	C703	C303	C103	C003	C043	C0C3		C706	C702	

شکل (۲): کد اختصاص داده شده به هر یک از حروف فارسی بنا بر فاصله همسایگی.

کناری آن به گونه‌ای تنظیم شده است که قواعد شاعع همسایگی رعایت شود. برای نمونه، کلید کناری آن حرف "ع" کد $0040_{(H)}$ یا $0000000010000000_{(2)}$ را گرفته که با حرف "غ" یک بیت اختلاف دارد و حرف "ه" نیز کد $0000000011000000_{(2)}$ یا $00C0_{(H)}$ را می‌گیرد که با حرف "ع" یک اختلاف و با حرف "غ" دو

اختلاف دارد و این اختلافات نشانگر فاصله همسایگی میان آنها است. شکل ۲ حروف فارسی و جایگاه آن بر صفحه کلید را به همراه کدهای شانزده‌شانزده‌ی مرتبه نشان می‌دهد. ورودی شبکه عصبی هر یک از حروف فارسی با شرح بیشتر در جدول ۲ درج گردیده است.

جدول (۲): حروف فارسی و کلید و کد آنها بنا بر فاصله همسایگی.

ردیف	حرف فارسی	کلید	کد هنگر	کد دودویی (ورودی شبکه عصبی)
۱	ا	h	8001	1.....1.....1
۲	ب	f	8301	1.....11.....1
۳	پ	\ يا	C706	11....111.....110
۴	ت	j	8041	1.....1.....11
۵	ث	e	0700111.....
۶	ج	[00F81111.....
۷	چ]	00FC11111.....
۸	ح	p	00F011111.....
۹	خ	o	00E0111.....
۱۰	د	n	C003	11.....1.....11
۱۱	ذ	b	C103	11.....1.....11
۱۲	ر	v	C303	11.....11.....11
۱۳	ز	c	C703	11.....111.....11
۱۴	ژ	C\ يا	C702	11.....111.....10
۱۵	س	s	8F01	1.....1111.....1
۱۶	ش	a	0F00	1...11111.....1
۱۷	ص	w	1F001111.....
۱۸	ض	q	CF03	11.....1111.....11
۱۹	ط	x	DF03	11.....1111.....11
۲۰	ظ	z	00401.....1.....
۲۱	ع	u	00001.....1.....
۲۲	غ	y	01001.....1.....
۲۳	ف	t	030011.....1.....
۲۴	ق	r	80F1	1.....11111.....1
۲۵	ک	:	80F9	1.....11111.....1
۲۶	گ	'	8101	1.....1.....111.....1
۲۷	ل	g	80E1	1.....1.....111.....1
۲۸	م	l	80C1	1.....1.....111.....1
۲۹	ن	k	C0C3	11.....111.....11
۳۰	و	,	00C0111.....11
۳۱	ه	i	8701	1.....111.....11
۳۲	ي	Z\d	C043	11.....1.....11
۳۳	ئ	m		

همان‌گونه که دیده می‌شود، در این مثال گزینه درست در اولیت چهارم پیشنهاد شده است و برخی از گزینه‌ها غیر منطقی به نظر می‌رسند.

۳- تصحیح غلط تایپی به کمک شبکه عصبی

شبکه عصبی مصنوعی روش و ابزاری محاسباتی است که بر روی مقادیر عددی کار می‌کند. بنابراین نخستین کار در چنین مساله‌ای این است که مفاهیم کیفی مانند حروف الفبا و دوری یا نزدیکی آنها به یکدیگر، به مقادیر کمی و عددی قابل محاسبه تبدیل شود. از این‌رو به هر یک از حروف صفحه کلید یک کد عددی به گونه‌ای اختصاص می‌یابد که مفهوم دوری / نزدیکی کلیدها را نیز در برداشته باشد.

۳-۱- تعریف فاصله (شعاع همسایگی) کلیدها

برای داشتن معیاری برای سنجش دوری یا نزدیکی دو حرف بر صفحه کلید، فاصله یا شاعع همسایگی دو کلید را چنین تعیین می‌کنیم:

- فاصله هر کلید با کلید کام کنارش برابر با ۱ است.
- فاصله هر کلید با کلید با کام برابر با ۲ است.
- فاصله هر کلید با کلید همسایه‌اش در سطر بالا یا پایین برابر با ۲ است.

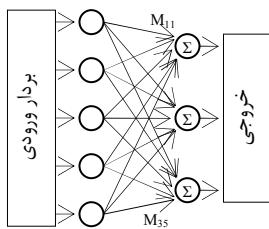
با توجه به این که در طولانی‌ترین سطر صفحه کلید ۱۲ حرف فارسی گنجانیده شده، یک کد ۱۶ بیتی می‌تواند فاصله کلیدهای هر ردیف را نشان دهد و از آنجا که ۳ ردیف حروف بر صفحه کلید موجود است و هر دو ردیف باید دست کم فاصله ۲ با هم داشته باشند، طول این کد به ۱۶ بیت افزایش می‌یابد. بنابراین با اختصاص این کدها (شکل ۲ و جدول ۲) می‌توان به هر یک از کلیدهای صفحه کلید یک کد ۱۶ بیتی منحصر به‌فرد اختصاص داد.

۲-۲- کدهای ورودی شبکه عصبی

برای تبدیل هر یک از حروف الفبای فارسی به یک مقدار عددی که به عنوان ورودی برای شبکه عصبی مصنوعی مناسب باشد، به جای این که هر یک از حروف با یکی از اعداد ۰ تا ۳۲ متناظر شود، به‌هر یک از آنها یک کد ۱۶ بیتی اختصاص یافته است. بدین منظور حرف "غ" مرکز کلیدهای فارسی با کد دودویی $0000000000000000_{(2)}$ و شانزده‌شانزده‌ی $0000_{(H)}$ در نظر گرفته شده است و کد کلیدهای

$$\begin{aligned} [1 \ 0 \ 1 \ 0] &= "ا" \\ [0 \ 1 \ 1 \ 0] &= "ب" \\ [1 \ 0 \ 1 \ 0] &= "پ" \\ [1 \ 1 \ 0 \ 1] &= "ر" \end{aligned}$$

شکل - ۳-(الف): کدگذاری و ذخیره واژگان به عنوان ورودی شبکه



شکل (۳-ب): شبکه عصبی حافظه یادآور

$$R = M \cdot S = \begin{bmatrix} 11010 \\ 01110 \\ 10101 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 3 \end{bmatrix}$$

شکل (۳-ب): بازیابی واژگان در شبکه حافظه یادآور به کمک ماتریس همبستگی

شبکه عصبی مصنوعی هاپفیلد شاخص ترین نوع شبکه‌های یادآور واژگونه حافظه خود یادآور^۴ است که کاربردهای بسیاری در دانش‌های گوناگون دارد. این شبکه نخستین بار در سال ۱۹۸۲ میلادی توسط جان هاپفیلد^۵ ارایه شد^[۱۵]. وی در سال ۱۹۸۵ این شبکه را به کمک تنک^۶ گسترش داد و با آن مساله فروشنده دوره گرد^۷ را با در نظر گرفتن ده شهر و صد نزون با کارایی بهتری حل کرد. فروشنده دوره گرد یک مسئله بهینه‌سازی معروف است که در زمرة مسائل بسیار مشکل قرار می‌گیرد و با روش‌های معمولی نمی‌تواند در زمانی معقول پاسخی بهینه را بدست آورد. هاپفیلد و تنک مسئله خود را تا ۳۰ شهر با موفقیت گسترش دادند و پس از گذشت ۲۰ سال هنوز هم روش آنها جزو بهترین الگوریتم‌های شبکه عصبی برای حل مسئله فروشنده دوره گرد است^[۱۶].

شبکه عصبی هاپفیلد در قالب یک سیستم پویا توسط یکتابع انرژی که باید تعادلی میان اهداف تابع مساله - که باید حداقل شود - ایجاد می‌کند^[۱۷]. پس از این موفقیت شبکه عصبی هاپفیلد، بسیاری از مسائل مهندسی در قالب تابع انرژی که باید کمینه شود، ارایه گردید. چنین راه حلی بسیار جذاب است، زیرا پردازش موازی را برای حل مسائل امکان پذیر می‌سازد^[۱۸].

بنابراین این شبکه می‌تواند با یادگیری و حفظ تعدادی واژه در حافظه خود، ورودی همراه با نویز یا همان غلط املای را به نزدیک‌ترین الگو نگاشت کند و صورت درست واژه را در خروجی تداعی کند. ساختار شبکه هاپفیلد در شکل ۴ و تابع فعالیت^۸ آن در شکل ۵

البته در عمل، مقادیر ورودی شبکه‌های عصبی نه به طور باینری، بلکه به صورت دوقطبی در نظر گرفته شده‌اند تا بازدهی شبکه بهتر باشد. پس هر یک از حروف واژگان، یک کد با ۱۶ ورودی ۱ یا ۰ را به خود

اختصاص می‌دهد و از این‌رو در لایه ورودی شبکه عصبی، ۱۶ نزون به هر یک از آنها اختصاص خواهد یافت.

۳-۳- فرهنگ واژگان به کار رفته در شبیه‌سازی

در شبیه‌سازی این پژوهش، ۶۰۰ واژه، ۴ حرفی به تعداد مساوی، برای آموزش شبکه‌ها و ۳۰۰ واژه نیز برای آزمایش به کار گرفته شده‌اند. بیشتر واژگان از اسامی اعلام (کسان و جای‌ها) یا کلمات پرکاربرد در زبان فارسی و از فرهنگ واژه‌های معتبر فارسی، مانند "لغت‌نامه دهخدا" و "فرهنگ معین"، برگزیده شده‌اند.

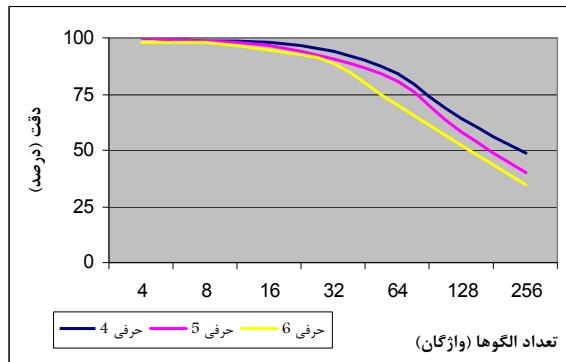
۴- شبیه‌سازی

شبیه‌سازی و آزمون مقادیر و واژگان توسط نرم‌افزار متلب^۹، به همراه نرم‌افزار کمکی تحت زبان ویژوال بیسیک^{۱۰} برای تهیه مقادیر ورودی دو نوع شبکه عصبی هاپفیلد و پرسپترون چند لایه^{۱۱} انجام شد. الگوهای ورودی در دسته‌های ۴، ۵ و ۶ حرفی به شبکه عصبی وارد شد و پس از آموزش شبکه، هر بار الگوهای ورودی به دفعات و با تغییر تصادفی یکی از حروف واژه آزموده شد.

۴-۱- شبیه‌سازی با شبکه عصبی هاپفیلد

هنگامی که درباره تصحیح املایی واژگان سخن می‌گوییم، شبکه‌های گونه حافظه یادآور^{۱۲} نخستین شبکه‌های مناسب به نظر می‌رسند. شبکه حافظه یادآور سیستمی است که می‌تواند داده‌های ذخیره شده (الگوهای^{۱۳}) را حتی با دیدن ورودهای همراه با غلط بازیابی (یادآوری) کند^[۱۴]. به عنوان نمونه‌ای کوچک برای آشنایی با روش کار این شبکه خط فارسی را به ۵ حرف ("ا", "ب", "ر", "ش" و "ی") محدود می‌کنیم و می‌خواهیم سه واژه "ابر", "آرش" و "بیش" را یاد گرفته، یادآوری نماییم. بر این پایه هر واژه را می‌توان بنا بر حروف مورد استفاده در آن به صورت یک ماتریس ۵ عنصری مانند شکل ۳-الف نمایش داد. این مساله به شبکه‌ای با ۵ گره ورودی و ۳ گره خروجی مانند شکل ۳-ب نیاز دارد. پاسخ آزمون واژه‌ای مانند "اید" - که همان واژه "یاد" با رخداد خطای انتقال است - از ضرب دو ماتریس فرهنگ واژگان در داده آزمایشی به دست آمده، سطر خروجی بزرگتر، پاسخ سیستم است. ماتریسی که فرهنگ واژگان را در بر دارد، ماتریس همبستگی^{۱۵} می‌نمایند.

نیشان داده شده است.



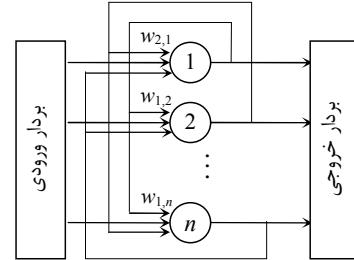
شکل (۶): نتایج شبکه هاپفیلد در تصحیح غلط تایپی واژگان ۴، ۵ و ۶ حرفی

همان‌گونه که در این جدول مشاهده می‌شود، با افزایش تعداد الگوهای دقت شبکه کاهش یافته است. همچنین افزایش تعداد حروف واژگان مورد آزمایش اندکی از دقت شبکه کاسته و برای یادگیری و تصحیح تنها ۲۵۶ واژه به بیش از ۲۵۰۰۰ دور گردش شبکه (اپک^۵) در هنگام آموزش نیاز است در صورتی که دقت تصحیح شبکه از ۵۵٪ فراتر نمی‌رود.

۴-۲- شبیه‌سازی با شبکه عصبی پرسپترون چند لایه

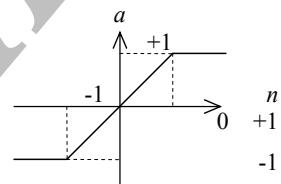
شبکه عصبی پرسپترون چند لایه، شبکه‌ای است که در اصل برای مسائل دسته‌بندی و تخمین تابع طراحی شده و در این کارها از موفق‌ترین شبکه‌های عصبی بوده و توانسته است با استفاده از قانون انتشار خطأ به عقب^۶ بسیاری از مسائل غیرقابل حل توسط شبکه‌های دیگر را حل کند [۱۹]. اما با توجه به این‌که کار اصلی این شبکه دسته‌بندی و تخمین تابع است، بنابراین به نظر نمی‌رسد که در مسأله تصحیح غلط تایپی - که می‌توان گفت مسأله یادآوری است - به کار آید.

نکته ساده‌ای که باید برای کارآمدی شبکه پرسپترون چند لایه در مسأله تصحیح واژه غلط به کار گرفت، این است که: اگر هر یک از الگوهایی که باید یاد گرفته شود را پا یک دسته در فضای n بعدی منتظر کنیم، برای یادگیری 2^n واژه، مسأله به مسأله دسته‌بندی 2^n دسته‌ای با n نرون در لایه خروجی شبکه منتظر می‌شود. پس برای نمونه، برای یادگیری مجموعه‌ای از واژگان با حدود ۶۵ هزار واژه، به شبکه‌ای با ۱۶ گره خروجی نیاز است. جدول ۴ نمونه‌ای از این روش را برای دسته‌بندی ۸ واژه چهار حرفی نیشان می‌دهد. واژه‌های مورد آزمایش به عمد به گونه‌ای برگزیده شده‌اند که بهم نزدیک باشند و با دیگرگونی یکی-دو حرف به واژه‌ای دیگر در واژه‌نامه تبدیل شوند، تا نتایج تصحیح بر روی آنها بهتر نمایان شود.



شکل (۴): نمای کلی شبکه هاپفیلد.

اما دو نقص بزرگ شبکه هاپفیلد ظرفیت پایین آن (در حدود ۱۵٪ اندازه شبکه یا تعداد گره‌ها) و همچنین هزینه محاسباتی بالای آن است [۱۹]. از این‌رو انتظار می‌رود که با افزایش تعداد الگوهای یاد داده شده، دقت شبکه کاهش یابد و بنابراین شبکه هاپفیلد نامزدی مناسب برای سیستم غلط‌یاب املاکی نیست [۴].



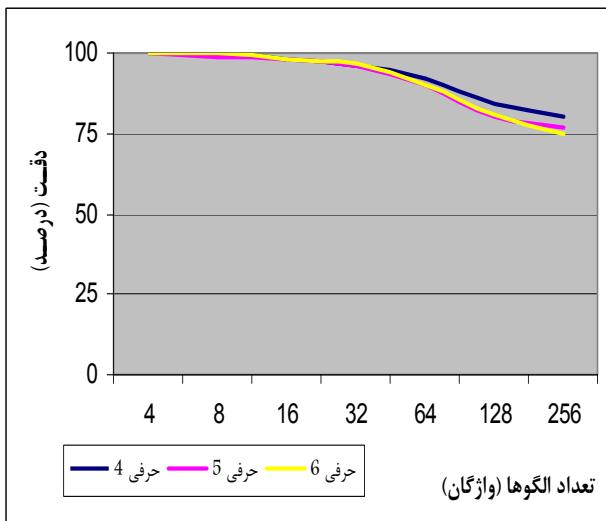
شکل (۵): تابع فعالیت (دو قطبی) شبکه هاپفیلد.

نتایج این آزمون و شبیه‌سازی آن در جدول ۳ و شکل ۶ نمایش داده شده است.

جدول (۳): ارزیابی نتایج شبکه هاپفیلد در تصحیح غلط تایپی واژگان.

ردیف	تعداد الگوها (واژگان)	تعداد حروف واژه	حداقل اپک لازم برای همگرا شدن شبکه	دقیق (درصد)
۱	۴	۴	۲۰	۱۰۰
۲	۴	۵	۵۰	۱۰۰
۳	۴	۶	۶۰	۹۸
۴	۸	۴	۱۰۰	۹۹
۵	۸	۵	۱۵۰	۹۹
۶	۸	۶	۲۰۰	۹۸
۷	۱۶	۴	۳۰۰	۹۸
۸	۱۶	۵	۵۰۰	۹۷
۹	۱۶	۶	۸۰۰	۹۵
۱۰	۳۲	۴	۱۰۰۰	۹۴
۱۱	۳۲	۵	۲۵۰۰	۹۱
۱۲	۳۲	۶	۴۰۰۰	۸۹
۱۳	۶۴	۴	۹۰۰۰	۸۴
۱۴	۶۴	۵	۱۲۰۰۰	۸۱
۱۵	۶۴	۶	۱۲۰۰۰	۷۰
۱۶	۱۲۸	۴	۲۰۰۰۰	۶۴
۱۷	۱۲۸	۵	۲۰۰۰۰	۵۸
۱۸	۱۲۸	۶	۲۰۰۰۰	۵۲
۱۹	۲۵۶	۴	۲۰۰۰۰	۴۹
۲۰	۲۵۶	۵	۲۰۰۰۰	۴۰
۲۱	۲۵۶	۶	۲۵۰۰۰	۳۵

جدول (۴): نمونه‌ای از ۸ واژه آزموده با شبکه عصبی و کد ویژه آنها.



شکل (۷): نتایج شبکه پرسپترون چند لایه در تصحیح واژگان ۴، ۵ و ۶ حرفی

جدول (۶): مقایسه میانگین بازدهی دو شبکه هاپفیلد و پرسپترون چند لایه

ردیف	تعداد الگوهای	هایپفیلد	پرسپترون چندلایه
۱	۴	۹۹/۳	۱۰۰
۲	۸	۹۸/۷	۹۹/۷
۳	۱۶	۹۶/۷	۹۸
۴	۳۲	۹۱/۳	۹۶/۳
۵	۶۴	۷۸/۳	۹۰/۷
۶	۱۲۸	۵۸	۸۱/۷
۷	۲۵۶	۴۱/۳	۷۷/۳

جدول‌های ۳ و ۵ به خوبی نشان می‌دهند که کارکرد شبکه پرسپترون چند لایه بسیار بهتر از شبکه هایپفیلد بوده است. جدول ۶ و شکل ۸ نیز این تفاوت را به صورت میانگین برای واژگان ۴ تا ۶ حرفی نشان می‌دهند.

۳-۴- ارزیابی نتایج

ردیف	واژه	کد باینری (دسته)
۱	نامی	...
۲	مانی	۰۰۱
۳	مینا	۰۱۰
۴	امین	۰۱۱
۵	میان	۱۰۰
۶	ایمن	۱۰۱
۷	نیما	۱۱۰
۸	نیما	۱۱۱

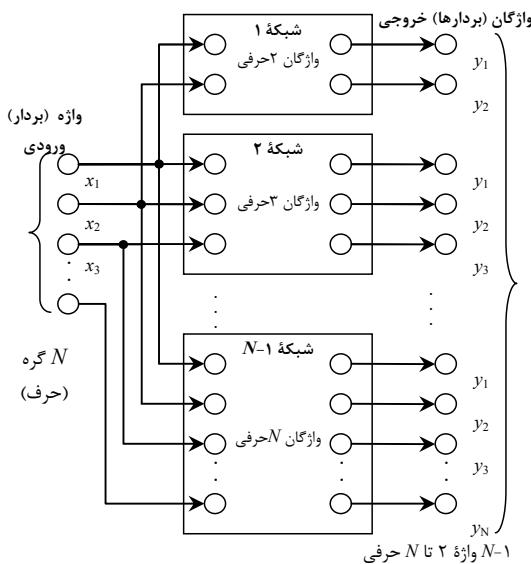
روشن است که این مجموعه نیاز به شبکه‌ای با ۳ نرون خروجی دارد. نتایج آزمایش با این روش با تعداد واژگان مختلف در جدول ۵ و شکل ۷ آمده است. در این آزمون‌ها، تعداد اپک‌ها به گونه‌ای تنظیم شده که خطای شبکه به صفر برسد، اما از آنجا که گاه این امر میسر نمی‌شود و با توجه به این که کار شبکه با تعداد دسته، لایه و نرون بسیار سنگین می‌شود (آموزش مورد ردیف ۱۹ بیش از ۳ روز زمان برده است!) کار با اپک‌های کمتر خاتمه یافته است.

همان‌گونه که مشاهده می‌شود، با افزایش تعداد الگوها، دقت شبکه کاهش می‌یابد. همچنین افزایش تعداد حروف واژگان مورد آزمایش اندکی از دقت شبکه کاسته است.

جدول (۵): ارزیابی نتایج شبکه پرسپترون چند لایه در تصحیح غلط تایپی واژگان.

ردیف	تعداد دسته‌ها	تعداد حروف	حداقل اپک (لازم یا نهاده) (درصد)	تعداد نرون‌های لایه	تعداد	ردیف
۱	۴	۴	۱۰	۲	۱۰۰	۱
۲	۴	۵	۱۵	۲	۱۰۰	۲
۳	۴	۶	۲۰	۲	۱۰۰	۳
۴	۸	۸	۵۰	۱	۱۰۰	۴
۵	۸	۵	۶۰	۱	۹۸	۵
۶	۸	۶	۸۰	۲	۱۰۰	۶
۷	۱۶	۱۶	۱۰۰	۲	۹۸	۷
۸	۱۶	۵	۱۴۰	۱	۹۸	۸
۹	۱۶	۶	۲۰۰	۲	۹۸	۹
۱۰	۳۲	۴	۵۰۰	۲	۹۶	۱۰
۱۱	۳۲	۵	۸۰۰	۲	۹۶	۱۱
۱۲	۳۲	۶	۱۳۰۰	۲	۹۸	۱۲
۱۳	۶۴	۶	۲۰۰۰	۲	۹۲	۱۳
۱۴	۶۴	۵	۳۰۰۰	۲	۹۰	۱۴
۱۵	۶۴	۶	۴۰۰۰	۲	۹۰	۱۵
۱۶	۱۲۸	۴	۱۰۰۰۰	۲	۸۴	۱۶
۱۷	۱۲۸	۵	۱۲۰۰۰	۲	۸۰	۱۷
۱۸	۱۲۸	۶	۱۵۰۰۰	۲	۸۱	۱۸
۱۹	۲۵۶	۴	۱۰۰۰۰	۳	۸۰	۱۹
۲۰	۲۵۶	۵	۱۲۵۰۰	۳	۷۷	۲۰
۲۱	۲۵۶	۶	۱۵۰۰۰	۳	۷۵	۲۱

در این شبکه، بردار واژه k حرفی به شبکه k و در صورت نیاز به شبکه‌های $k-1$ وارد می‌شود و بنابراین پاسخ تنها در خروجی شبکه‌های k و $k-1$ ظاهر می‌گردد.



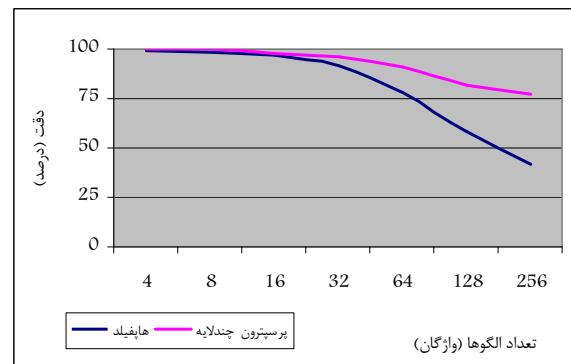
شکل (۹): به کارگیری شبکه‌های موازی در پردازش واژگان ۲ تا N حرفی

جدول ۷ نتایج آزمون روش تقسیم‌بندی بر پایه طول واژه را بر واژگان ۴ تا ۶ حرفی با ۳ زیرشبکه که هر یک از آنها ۴ تا ۲۵۶ واژه را یاد گرفته‌اند، نشان می‌دهد. در صورتی که واژه درست مرتبط با واژه غلط مورد آزمایش، دست کم در یکی از خروجی‌های سیستم ظاهر شده باشد، عملکرد شبکه درست در نظر گرفته شده است.

جدول (۷): افزایش ظرفیت با روش تقسیم‌بندی طول واژه.

پرسپترون چندلایه	هاپفیلد	تعداد کل واژگان	ردیف الگوهای هر واژگان	تعداد شبکه
۱۰۰	۹۹/۳	۱۲	۴	۱
۹۹/۵	۹۸/۲	۲۴	۸	۲
۹۷/۲	۹۵/۵	۴۸	۱۶	۳
۹۴/۱	۸۹/۱	۹۶	۳۲	۴
۸۸/۷	۷۳	۱۹۲	۶۴	۵
۷۹/۸	۵۰/۵	۳۸۴	۱۲۸	۶
۷۲	۳۵	۷۶۸	۲۵۶	۷

تقسیم‌بندی بر پایه نوع واژه: در هنگام آموزش و دسته‌بندی واژگان k حرفی، می‌توان واژگان را به جای یک شبکه، در N شبکه پخش کرد. این ترفند ظرفیت کل سیستم را به طور متوسط N برابر افزایش می‌دهد و گذشته از آن، امکان پیشنهاد چندین واژه جایگزین در خروجی را هم پدید می‌آورد. روشن است که گره‌های لایه ورودی و خروجی این شبکه نیز، که در شکل ۱۰ نمایش داده شده است، هر یک



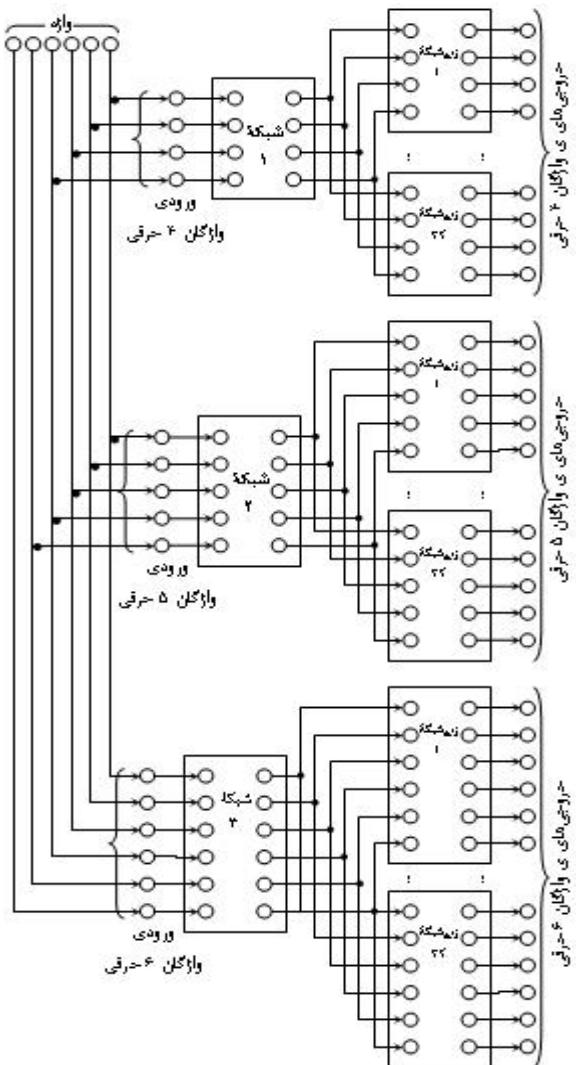
شکل (۸): بازدهی دو شبکه هاپفیلد و پرسپترون چندلایه.

۴-۴- ترمیم مشکل ظرفیت شبکه

همان‌گونه که از نتایج شبیه‌سازی بر می‌آید، پایین بودن ظرفیت این دو شبکه عصبی بزرگترین مشکل بر راه اجرایی شدن طرح است و برطرف ساختن آن ساده به نظر نمی‌رسد؛ زیرا شبکه هاپفیلد اصولاً ظرفیتی پایین دارد و تنها با اعمال برخی تغییرات ساختاری بر آن می‌توان ظرفیت شبکه را تا چند برابر افزایش داد، که آن نیز از نزدیکترین مرز نیاز دور است. شبکه پرسپترون چندلایه نیز - به رغم عملکرد ممتاز نسبت به دیگر شبکه‌ها - با توجه به ماهیت مسئله این پژوهش، امکان افزایش چشمگیر ظرفیت با تنظیمات کنونی را ندارد.

البته هر چند که مشکل ظرفیت مانع اصولی بر راه انجام و پیشبرد پژوهش در به کارگیری شبکه‌های عصبی مصنوعی برای اجرای طرح تصحیح غلط املایی و تایپی نخواهد بود و با پیدایش شبکه‌های پرتوان‌تر یا استفاده بهینه‌تر از شبکه‌های موجود، این مسئله حل خواهد شد، اما به هر حال ارایه روش‌هایی مستقل از نوع شبکه‌ها برای افزایش ظرفیت سیستم سودمند خواهد بود که در ذیل به دو مورد اشاره می‌شود:

تقسیم‌بندی بر پایه طول واژه: با توجه به ماهیت شبکه که ورودی‌های گسسته مشکل از واژگان ۲ تا N حرفی (حدود ۱۰) با ۳۳ نوع حرف ("ا" تا "ی" و "ء") دارد، می‌توان آن را مانند شبکه ۹ به $N-1$ شبکه مستقل برای پردازش واژگان ۲ تا N حرفی تقسیم کرد. روشن است که هر یک از گره‌های لایه ورودی یا خروجی این شبکه برای نمایش حروف، خود از شانزده نرون باینری یا دو فطیبی تشکیل می‌شود. این تدبیر ظرفیت کل سیستم را به طور متوسط $N-1$ برابر افزایش می‌دهد. دیگر مزیت این کار، رفع مشکل درج و حنف حرف در واژگان است که بسته به نیاز، با آزمون واژگان i حرفی در شبکه‌های $i+1$ و $1-i$ انجام خواهد شد.

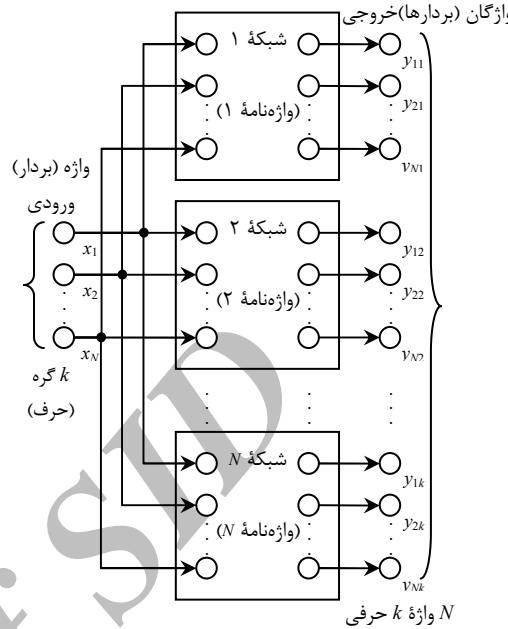


شکل (۷): افزایش ظرفیت با تکیب شبکه‌ها.

۵- نتیجه‌گیری

در این پژوهش کوشش شد تا به‌کمک شبکه عصبی مصنوعی روشی برای کشف و تصحیح غلطهای املایی برآمده از خطاهای تایپی کاربر ارایه شود. بدین منظور بنا بر یک قرارداد مبتنی بر فاصله دکمه‌های صفحه کلید، کدی ۱۶ بیتی به هر یک از حروف اختصاص داده شد تا شبکه عصبی از روی آن همسایگی را تشخیص دهد. سپس نخست واژگان در گروه‌های ۴، ۵ و ۶ حرفی و دسته‌های ۴ تا ۲۵۶ واژه‌ای با دو نوع شبکه عصبی هاپفیلد و پرسپترون چند لایه آزموده شدند. نتایج این آزمون‌ها نشان داد که شبکه هاپفیلد از دقت عملکرد ۱۰۰٪ درستی برای تصحیح غلطهای تایپی فرهنگ لغتی با ۴ واژه، به دقت درستی کمتر از ۴۲٪ برای تصحیح غلطهای تایپی فرهنگ لغتی با ۲۵۶ واژه می‌رسد؛ در حالی که شبکه عصبی پرسپترون چندلایه چنین فرهنگ واژگانی را با بیش از ۷۷٪ دقت درستی غلطهای تایپی می‌کند. از این‌رو با اطمینان می‌توان گفت که شبکه پرسپترون چند لایه، در این مساله یادآوری بهتر از شبکه هاپفیلد کار می‌کند. افزون بر این، گذشته از آن که دقت عملکرد دو شبکه در هنگام افزایش واژگان کاهش

نشانگر شانزده نرون هستند. در این شبکه، بردار واژه k حرفی به تمام شبکه‌ها وارد می‌شود و بنابراین در همه خروجی‌های N شبکه، پاسخ ظاهر می‌گردد.



شکل (۱۰): پخش واژگان در شبکه‌های موازی.

جدول ۸ نتایج آزمون روش تقسیم‌بندی برپایه نوع واژه را بر واژگان ۵ حرفی با شبکه‌های متاشکل از ۴ تا ۳۲ زیرشبکه که هر یک از آنها ۳۲ واژه را یاد گرفته‌اند، نشان می‌دهد.

جدول (۸): افزایش ظرفیت با روش تقسیم‌بندی نوع واژه.

ردیف	تعداد زیرشبکه	تعداد کل واژگان	تعداد هاپفیلد چندلایه	پرسپترون
۱	۴	۱۲۸	۹۰/۱	۹۵
۲	۸	۲۵۶	۸۸/۱	۹۴/۷
۳	۱۶	۵۱۲	۸۲/۱	۹۰/۹
۴	۳۲	۱۰۲۴	۷۷/۷	۸۶/۱

شبکه ترکیبی: با ترکیب این دو شبکه بالا، در حالتی که سیستم غلظیاب از ۳ شبکه ۴ تا ۶ حرفی، هر یک با ۳۲ زیرشبکه تقسیم شده بر پایه ۳۲ واژه (در مجموع ۳۰۷۲ واژه) شکل گرفته است، کارایی سیستم به دقت ۷۰ درصد در شبکه هاپفیلد و ۷۹/۶ درصد در شبکه پرسپترون چند لایه رسید. شکل ۱۱ نمای کلی این شبکه را نشان می‌دهد.

در این سیستم، هر واژه k حرفی تنها به ورودی شبکه متناظرش وارد می‌شود و هر واژه ۳۲ خروجی خواهد داشت.



- می یافتد، با افزایش حروف واژگان نیز با کاهشی محسوس روبرو می گردد.
- همچنین در گام بعدی با تقسیم واژگان و آذنامه در گروههای کوچکتر بر پایه طول و نوع واژگان و آموزش آنها در شبکههای جداگانه و سپس ترکیب این شبکهها، ظرفیت سیستم غلطیاب - با حفظ نسبی دقت - به اندازهای چشمگیر افزایش یافت، به گونهای که بیش از ۳۰۰۰ واژه با دقت درستی ۸۰ درصد تصحیح گردید.
- البته روش‌های ارایه شده در این پژوهش، به ترتیب در صورتی خوب کار می کند که حروف واژه مورد آزمون اشتباہ، کم یا اضافه تایپ شده باشد و در مورد خطاهای ناشی از انتقال حروف در واژه، دیگر روش‌های موجود کارآمدتر هستند.
- همچنین اهداف زیر دستور کارهای آینده قرار دارد:
 - آزمایش تعداد واژگان بیشتر تا دست کم ۱۶ هزار کلمه که مقداری مناسب برای فرهنگ واژگان است.
 - آزمایش شبکههای عصبی دیگر برای دستیابی به نتایج بهتر، به ویژه شبکههای عصبی فازی^{۳۲}
 - تنظیم بهتر تعداد لایه‌ها و نرون‌های هر لایه در شبکه پرسپترون چندلایه
 - یافتن نقطه بینه برای حداکثر تعداد اپک‌های شبکه
 - ادغام واژگان با تعداد حروف مختلف در یک شبکه
 - بهینه‌سازی کدهای حروف صفحه‌کلید و کاهش طول آنها.

مراجع

زیرنویس‌ها

-
- ¹ Natural Language Processing / Understanding
² Text Mining
³ Spell Checking
⁴ Syntax Checking
⁵ Concept Checking
⁶ Grammatical Confusion / Grammos
⁷ Phonological Similarity / Phonos
⁸ Typing Errors / Keyboard Mistyping / Typus
⁹ Insertion
¹⁰ Deletion
¹¹ Substitution
¹² Transposition (Interchange)
¹³ Spelling Errors
¹⁴ Transmission and Storage Errors
¹⁵ Optical Character Recognition (OCR)
¹⁶ Automatic Mode
¹⁷ Interactive Mode
¹⁸ Spelling Correction
¹⁹ String Substitution
²⁰ Reversal Errors

- [1] Allen James, *Natural Language Understanding*, The Benjamin/Cummings Publishing Co., 2nd Edition, 1994.
- [2] Patrick Ruch, Robert Baud and Antoine Geissbuhler, "Toward filling the gap between interactive and fully-automatic spelling correction using the linguistic context", IEEE International Conference on Systems, Man, and Cybernetics 1 (2001) 199-204.
- [3] Patrick Ruch, Robert Baud and Antoine Geissbuhler, "Using lexical disambiguation and named-entity recognition to improve spelling correction in the electronic patient record", Artificial Intelligence in Medicine 29 (2003) 169-184.
- [4] V. Cherkassky, N. Vassilas and G. L. Brodt, "Conventional and associative memory-based spelling checkers", Proceedings of the 2nd International IEEE Conference on Tools for Artificial Intelligence (1990) 138-144.
- [5] V.J. Hodge, J. Austin, "A comparison of a novel neural spell checker and standard spell checking algorithms", Pattern Recognition 35 (11) (2002) 2571-2580.
- [6] Dominique Lavenier, "A high performance systolic chip for spelling correction", Euro ASIC '92, Proceedings 1 (1992) 381-384.
- [7] R. Garfinkel., E. Fernandez, R. Gopal, "Design of an interactive spell checker: optimizing the list of offered words", Decision Support Systems 35 (2003) 385- 397.
- [8] K. Kukich, "Techniques for automatically correcting words in text", ACM Comput Surveys 24 (4) (1992) 377-439.
- [9] J.R. Ullman, "A binary n-gram technique for automatic

-
- ²¹ String Matching
 - ²² Erroneous Word
 - ²³ Edit Distance
 - ²⁴ Hamming Distance
 - ²⁵ Levenshtein Distance
 - ²⁶ CorrectStar
 - ²⁷ Trie Algorithm
 - ²⁸ n-gram
 - ²⁹ Bangla
 - ³⁰ Fuzzy Approximate Word-Matching
 - ³¹ Associative Memory
 - ³² Hopfield
 - ³³ Backpropagation Networks
 - ³⁴ Dictionary Look-up Methods
 - ³⁵ Exact Matching

۳۶ حروف‌چین‌ها به دو دسته تقسیم می‌شوند: یکی آنها که هر چه را که می‌بینند، تایپ می‌کنند و دیگر، آنان که خواسته یا ناخواسته متن را می‌فهمند و سپس تایپ می‌کنند. هر چند که یافتن فردی از گوئه دوم برای تایپ موهبتی است و مزایای بسیار دارد، اما احتمالاً از آنجا که فرد نجیبت واژه را در مغز خود پردازش می‌کند و سپس آنرا تایپ می‌کند و گاه سرعت دست از سرعت پردازش برخی از واژگان در مغز بیشتر می‌شود، احتمال خطای املایی نیز در این افراد پیش می‌آید.

- ³⁷ Virtual Space
- ³⁸ Back Space
- ³⁹ Microsoft Word
- ⁴⁰ Matlab
- ⁴¹ Visual Basic
- ⁴² Multi-Layer Perceptron
- ⁴³ Neural Associative Memories
- ⁴⁴ Pattern
- ⁴⁵ Correlation Matrix
- ⁴⁶ Auto-Associative Memory
- ⁴⁷ John J. Hopfield
- ⁴⁸ Tank D. W.
- ⁴⁹ Traveling salesman problem
- ⁵⁰ Activation Function
- ⁵¹ Epochs
- ⁵² Back-Propagation
- ⁵³ Neuro-Fuzzy Networks

