



۱. (۱۵٪) [مطالعه و بررسی] توابع فعال‌سازی (Activation functions) زیر را که بر مبنای تاریخ توسعه مرتب شده‌اند، در نظر بگیرید:

- Sigmoid
- Tanh
- Parametric Leaky Tanh (PLTanh)
- Softmax
- Rectified Linear Unit (ReLU)
- Leaky ReLU
- PReLU
- Exponential Linear Unit (ELU)
- Trivialized Exponential Linear Unit (TeLU)
- Scaled Exponential Linear Unit (SeLU)
- Maxout
- Gelu
- Swish
- Mish

۱-۱ نمودار هر یک از آنها را به ازای متغیر  $x$  در بازه  $x \in [-5, 5]$  رسم کنید.  
۲-۱ تابع گرادینان هر کدام از توابع را نسبت به متغیر  $x$  در بازه  $x \in [-5, 5]$  بدست آورید و آنها را رسم کنید.

۳-۱ کدام یک از توابع فعال‌سازی بالا مناسب برای مسائل دوکلاسه (Binary Classification) و کدام یک مناسب برای مسائل چندکلاسه (Multi Class Classification) مناسب هستند؟

۲. (۴۵٪) [پیاپیاده‌سازی: پرسپترون و آدالاین] مسئله‌ی بازشناسی نویسه را برای الگوهای بیان شده در مثال ۲-۱۵ در فصل دوم کتاب، با استفاده از ساختار شبکه نشان داده شده در شکل ۲-۲۱ پیاده‌سازی



کنید. بدین منظور الگوهای آموزش شکل ۲-۲۰ و الگوهای آزمون (تست) شکل ۲-۲۲ که به صورت فایل های متنی به همراه تمرین ارائه شده است، به کار بگیرید. برای موارد زیر نتیجه را گزارش کنید. در گزارش ها درصد خطای بازشناسی را به صورت زیر محاسبه و گزارش کنید.

$$Error Rate = \frac{N_{err}}{N} \times 100 = \frac{\text{تعداد الگوهایی که اشتباهی بازشناسی شده اند}}{\text{تعداد کل الگوها}} \times 100$$

نکته: برای بهتر دیدن الگوهای ارائه شده در فایل های متنی، می توانید از فونت Courier New یا CourierPS در NotePad استفاده کنید.

۱-۲ (۲۰٪) [پرسپترون] آموزش شبکه را با استفاده از قانون پرسپترون و با در نظر گرفتن موارد خواسته شده در بخش های زیر انجام دهید. توجه شود در هر بخش جدید، بهترین پارامترهای پیدا شده در بخش های پیشین را به عنوان مقادیر پیش فرض در نظر بگیرید:

**الف) [مقادیر اولیه]** در این بخش قصد داریم درصد خطای بازشناسی را برای داده های آزمون، به ازای اجزای مختلف از مقادیر مختلف اولیه وزن ها و بایاس های شبکه پیدا کنیم. در این راستا این مقادیر را با روش های زیر تولید کرده و سپس درصد خطای بازشناسی و زمان همگرایی را برای داده های آموزش گزارش کنید. با استفاده از نتایج، در مورد اثر مقادیر اولیه بر کارایی و سرعت شبکه بحث کنید. روش های تولید وزن اولیه:

۱- همه صفر

۲- مقادیر تصادفی با توزیع یکنواخت

۳- مقادیر تصادفی با توزیع نرمال

۴- روش Xavier(Glorot)

۵- روش Kaiming(HE)

**ب) [مقدار آستانه]** برنامه را با بهترین روش بخش الف، برای چند مقدار مختلف آستانه  $\theta$  تکرار کنید و نتایج بازشناسی را برای داده های آزمون ارائه کنید. آیا مقدار بیشتر  $\theta$  تأثیری بر درصد خطای شبکه دارد؟



ج) [نرخ یادگیری] شبکه را با بهترین روش بخش الف و ب، برای پنج مقدار مختلف از نرخ یادگیری، ۰.۵، ۰.۱، ۰.۰۵ و ۰.۰۱ آموزش دهید و نتیجه بازشناسی بر روی داده‌های آزمون را به صورت نمودار رسم کنید. زمان همگرایی شبکه را در هر حالت گزارش کنید. با توجه به نتایج حاصل، در مورد تاثیر این پارامتر بر عملکرد شبکه بحث کنید.

۲-۲ (۱۵٪) [آدالاین] شبکه را با استفاده از قانون آدالاین (دلتا) و با بهترین پارامترهای پیدا شده در قسمت‌های قبل سوال (نرخ یادگیری، وزن‌های اولیه و بایاس) آموزش دهید و نتیجه بازشناسی را برای داده‌های آزمون و داده‌های آموزش گزارش کنید.

۳-۲ (۲.۵٪) [مقایسه] بهترین نتایج بدست آمده را روی هر دو مجموعه آموزش و آزمون در ۳ پیاده‌سازی مربوط به پرسپترون و پیاده‌سازی مربوط به آدالاین، در یک جدول بیاورید. نتایج را مقایسه کرده و علل تفاوت نتایج را شرح دهید.

۴-۲ (۲.۵٪) [داده نویزی] برای حالتی که برای الگوی تست، بیش از یکی از دسته‌ها انتخاب می‌شوند، چه راهکاری را پیشنهاد می‌کنید. روش خود را پیاده‌سازی کرده و نتیجه را برای شبکه پرسپترون گزارش کنید.

۵-۲ (۵٪) [استخراج ویژگی] در بخش‌های قبل از این تمرین، مقدار کل پیکسل‌های هر نویسه به عنوان ورودی شبکه استفاده شد. در این بخش، از روش تصویر کردن (projection) برای استخراج ویژگی استفاده می‌شود و مقدار ویژگی‌ها (به جای مقادیر پیکسل‌ها) به عنوان ورودی به شبکه داده می‌شود. در این روش، به ازای هر ردیف (و هر ستون) از هر نویسه، مجموع پیکسل‌های روشن (با مقدار یک) آن ردیف (یا ستون) شمارش شده و مقدار حاصل جمع به عنوان ویژگی در نظر گرفته می‌شود. با توجه به ابعاد نویسه‌ها که  $9 \times 7$  هستند، تعداد ویژگی‌های هر نویسه  $9 + 7 = 16$  خواهد بود.

شبکه آدالاین را برای آموزش با ویژگی‌های حاصل تغییر دهید و نتایج حاصل را (نرخ خطا روی مجموعه آزمون) در یک جدول گزارش کنید. آیا کارایی شبکه‌ها در این حالت، به نسبت حالتی که مقدار خود پیکسل‌ها استفاده شود، بهبود می‌یابد یا خیر؟ در هر صورت، تحلیل خود را از این نتایج بیان کنید.



۳. (۴۰٪) [پایاده سازی: تحلیل ریزش مشتری با شبکه عصبی] در بسیاری از کسب و کارهای مبتنی بر اشتراک، مانند شرکت های مخابراتی، سرویس های پخش آنلاین، بانک ها و پلتفرم های محتوایی، مشتریان ممکن است در مقاطع زمانی مختلف تصمیم بگیرند استفاده از خدمات را متوقف کنند. این پدیده در علم داده و بازاریابی با عنوان ریزش (Churn) یا Customer Attrition شناخته می شود و بیانگر از دست دادن مشتریان در طول زمان است. شناسایی و پیش بینی مشتریانی که در آستانه ترک سرویس هستند، یکی از چالش های اصلی تحلیل رفتار کاربران محسوب می شود؛ زیرا نگاهداشت مشتریان موجود معمولاً از جذب مشتریان جدید مقرون به صرفه تر است. در یادگیری ماشین، مسئله پیش بینی ریزش به صورت یک مسئله طبقه بندی دودویی مدل می شود، که در آن هدف، پیش بینی برچسب ۱ برای کاربران ترک کننده و برچسب ۰ برای کاربران وفادار است. این پیش بینی به شرکت ها کمک می کند تا با طراحی راهکارهای شخصی سازی شده و مداخلات هدفمند، احتمال از دست دادن کاربران را کاهش دهند.

اسپاتیفای (Spotify) یکی از بزرگ ترین سرویس های پخش موسیقی آنلاین در جهان است که کاربران می توانند از آن برای گوش دادن به موسیقی، ساخت پلی لیست، و دنبال کردن هنرمندان استفاده کنند. ز آنجا که کاربران به راحتی می توانند اشتراک خود را لغو کنند، پیش بینی احتمال ریزش برای شرکت بسیار مهم است. تحلیل داده های استفاده کاربران (مثل زمان گوش دادن، دفعات ورود، تعداد آهنگ ردا شده، و غیره) می تواند الگوهای رفتاری منجر به ریزش را آشکار کند.

دادگان Spotify Churn Analysis شامل اطلاعات حدود ۸۰۰۰ کاربر سرویس پخش موسیقی اسپاتیفای است و برای تحلیل و پیش بینی رفتار ترک سرویس طراحی شده است. هر ردیف در این مجموعه داده بیانگر ویژگی های فردی و رفتاری یک کاربر است. متغیرها شامل مشخصات جمعیت شناختی مانند جنسیت (gender)، سن (age) و کشور (country)، نوع اشتراک (subscription\_type) و الگوهای استفاده از سرویس مانند زمان گوش دادن روزانه (listening\_time)، تعداد آهنگ های پخش شده در (songs\_played\_per\_day)، نرخ رد کردن آهنگ ها (skip\_rate)، نوع دستگاه مورد استفاده (device\_type) و تعداد تبلیغات شنیده شده در هفته (ads\_listened\_per\_week) هستند. همچنین ستون offline\_listening نشان می دهد که آیا کاربر از



حالت آفلاین استفاده کرده است یا خیر. متغیر هدف (`is_churned`) به صورت دودویی تعریف شده است، که مقدار ۱ نشان‌دهنده‌ی کاربران ترک‌کننده و مقدار ۰ نشان‌دهنده‌ی کاربران فعال است. این مجموعه داده ترکیبی از ویژگی‌های عددی و رده‌ای (`numeric` و `categorical`) دارد و برای ساخت مدل‌های یادگیری ماشین در زمینه‌ی پیش‌بینی ترک کاربر، تحلیل الگوهای تعامل، و بهبود راهبردهای حفظ مشتریان اسپاتیفای استفاده قرار می‌گیرد.

۱-۳ (۲.۵٪) [تحلیل مقدماتی داده] در نخستین گام، لازم است ساختار کلی مجموعه داده بررسی شود. دانشجو باید با بارگذاری فایل داده، ابعاد آن (تعداد سطر و ستون)، نام ستون‌ها و نوع داده‌ی هر ویژگی را مشاهده کند تا درک اولیه‌ای از ماهیت داده به دست آید. سپس با استفاده از توابع آماری نظیر `describe()` و `info()` شاخص‌هایی مانند میانگین، انحراف معیار، بیشینه و کمینه‌ی متغیرها استخراج می‌شود تا رفتار عددی آن‌ها مشخص گردد. پس از آن، باید وجود مقادیر گمشده (`NaN`) یا مقادیر پرت (`outliers`) شناسایی شود. در پایان، توزیع مقادیر در متغیر هدف `is_churned` بررسی می‌شود تا مشخص گردد آیا داده نامتوازن (`imbalanced`) است یا خیر. در صورت وجود نامتوانی، دانشجو باید توضیح دهد که این پدیده چگونه می‌تواند باعث سوگیری مدل به سمت کلاس اکثریت شود و چه روش‌هایی برای مقابله با آن وجود دارد؟

۲-۳ (۲.۵٪) [تبدیل ویژگی‌ها] از آنجا که بسیاری از مدل‌های یادگیری ماشین از جمله پرسپترون و آدالین فقط با داده‌های عددی کار می‌کنند، لازم است ویژگی‌های غیر عددی (`categorical`) مانند `gender`, `country`, `subscription_type` و `device_type` به داده‌های عددی تبدیل شوند. این تبدیل را می‌توان با دو روش انجام داد: `Label Encoding` که به هر دسته یک عدد یکتا اختصاص می‌دهد، و `One-Hot Encoding` که برای هر مقدار ممکن از دسته، یک ستون جداگانه ایجاد می‌کند. انتخاب روش مناسب باید با توجه به ماهیت داده انجام شود؛ برای مثال، اگر متغیر دارای ترتیب طبیعی نباشد (مثل نوع دستگاه یا کشور)، `One-Hot Encoding` مناسب‌تر است. در پایان این مرحله، تمامی ستون‌های داده باید عددی و قابل استفاده برای مدل‌سازی باشند.

۳-۳ (۲.۵٪) [بررسی همبستگی ویژگی‌ها] پیش از مدل‌سازی، لازم است بررسی شود کدام ویژگی‌ها با یکدیگر یا با متغیر هدف همبستگی دارند. ابتدا ستون `user_id` حذف می‌شود، زیرا



شناسه‌ای یکتا است و هیچ ارزش تحلیلی ندارد. سپس با استفاده از تابع `corr()` ماتریس همبستگی میان ویژگی‌های عددی محاسبه می‌شود و به کمک نمودار حرارتی (`heatmap`) نمایش داده می‌شود. این ماتریس نشان می‌دهد که کدام متغیرها ارتباط مثبت یا منفی قوی با یکدیگر یا با متغیر هدف دارند. دانشجو باید تحلیل کند آیا برخی ویژگی‌ها دارای همبستگی بالا هستند (که می‌تواند منجر به افزونگی اطلاعات شود) و کدام ویژگی‌ها بیشترین تأثیر را بر متغیر `is_churned` دارند.

۳-۴ (۲.۵٪) [رفع نامتوازن داده] در صورتی که کلاس‌های داده نامتوازن باشند، مدل تمایل خواهد داشت کلاس اکثریت را بیشتر پیش‌بینی کند. برای جلوگیری از این مسئله، در این تمرین از روش `Random Undersampling` استفاده می‌شود. در این روش، نمونه‌هایی از کلاس بزرگ‌تر به صورت تصادفی حذف می‌شوند تا تعداد نمونه‌های دو کلاس برابر شود. این کار موجب می‌شود مدل بدون سوگیری نسبت به هیچ کلاس خاصی آموزش ببیند. هرچند `Undersampling` موجب از دست رفتن بخشی از داده می‌شود، اما برای تمرین‌های آموزشی و مدل‌های سبک مانند `Adaline` و `Perceptron` گزینه‌ای ساده و مؤثر است. پس از اجرای این روش، دانشجو باید نسبت کلاس‌ها را قبل و بعد از بالانس بررسی و درباره تأثیر آن بر عملکرد مدل توضیح دهد.

۳-۵ [تقسیم داده و نرمال‌سازی] در این مرحله داده‌ی متعادل‌شده به دو بخش آموزش (`train`) و آزمون (`test`) تقسیم می‌شود تا عملکرد مدل بتواند روی داده‌های دیده‌نشده سنجیده شود. نسبت پیشنهادی تقسیم ۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون است. سپس ویژگی‌ها باید استاندارد شوند تا میانگین صفر و انحراف معیار یک داشته باشند؛ این فرآیند با استفاده از `StandardScaler` انجام می‌شود.

۳-۶ (۳۰٪) [آموزش و مقایسه مدل‌ها] در گام نهایی، دو مدل یادگیری خطی کلاسیک، یعنی `Perceptron` و `Adaline` روی داده‌ی آماده‌شده آموزش داده می‌شوند. پرسپترون از تابع فعال‌سازی پله‌ای استفاده می‌کند و بر اساس قانون یادگیری خطی ساده عمل می‌کند، در حالی که آدلاین از تابع هزینه میانگین مربعات و به‌روزرسانی تدریجی وزن‌ها بهره می‌گیرد. هر دو مدل پس از آموزش باید روی داده‌ی آزمون ارزیابی شوند. معیارهای ارزیابی شامل `Accuracy` دقت کلی، `Precision` دقت پیش‌بینی‌های کلاس مثبت، `Recall` توانایی مدل در شناسایی کاربران ترک‌کرده، `F1-score` (میانگین

بر نام خدا

مبانی محاسبات (رایانش) نرم (۰۱-۰۳۹-۰۵-۸۳)  
نیمسال اول ۱۴۰۴-۱۴۰۵



تاریخ تحویل: ۱۴۰۴/۰۸/۲۱

تمرین شماره ۱

---

موزون دقت و یادآوری)، و Confusion Matrix برای مشاهده‌ی توزیع خطاهاست. در پایان، دانشجو باید نتایج دو مدل را مقایسه کرده و درباره‌ی تفاوت در همگرایی، حساسیت به نویز، و پایداری هر مدل تحلیل کوتاهی ارائه دهد.

---