

تشخیص اردک‌های بیمار بر اساس صدای آنها و به کمک روش‌های هوش مصنوعی

احمد بناکار^{۱*}، مقداد خزایی^۲

۱. استادیار، گروه مکانیک ماشین‌های کشاورزی دانشگاه تربیت مدرس

۲. دانشجوی دکتری، گروه مکانیک ماشین‌های کشاورزی دانشگاه تربیت مدرس

(تاریخ دریافت: ۱۳۹۲/۱۰/۱۸ - تاریخ تصویب: ۱۳۹۴/۱۰/۱۵)

چکیده

در این مقاله روشی هوشمند به منظور طبقه‌بندی اردک‌های سالم و بیمار بر اساس صدای منتشره از آن‌ها طراحی و به کار گرفته شده است. بدین منظور ابتدا پرندگان بر اساس وضعیت سلامتی به دو طبقه سالم و بیمار تقسیم و صدای هر یک توسط یک میکروفن ثبت شد. سیگنال‌های تحصیل شده توسط تبدیل سریع فوریه از حوزه‌ی زمان به حوزه فرکانس انتقال یافتند. سپس ۵ تابع ویژگی واریانس، انحراف از معیار، ریشه‌ی میانگین مربعات، میانگین و کورتسیس از سیگنال‌های حوزه‌ی زمان و فرکانس استخراج شدند. از دو طبقه‌بند شبکه عصبی مصنوعی و ماشین بردار پشتیبان به منظور شناسایی سیگنال‌های صدا استفاده شد. شبکه عصبی مصنوعی توانست به ترتیب با دقت ۷۵ و ۸۲/۱ درصد و ماشین بردار پشتیبان نیز به ترتیب با دقت ۸۵/۷ و ۹۲/۸ درصد بر اساس سیگنال‌های حوزه زمان و حوزه فرکانس، سیگنال‌های صدای مربوط به اردک‌های بیمار و سالم را از یکدیگر تشخیص دهند.

واژه‌های کلیدی: تشخیص پرندگان بیمار، سیگنال‌های صدا، داده‌کاوی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان.

مقدمه

آنالیز صدای پرندگان، تشخیص، شناسایی و در گام بعد طبقه‌بندی آنها دارای سابقه‌ی کوتاهی می‌باشد و به تازگی محققین به اهمیت آن پی برده‌اند. در واقع صدایی که حیوانات منتشر می‌کنند حاوی اطلاعات بسیار ارزشمندی از آنهاست که از جمله‌ی مهم‌ترین آنها می‌توان به وضعیت سلامت و ضعف، بیماری، نوع، اندازه‌ی جثه، گونه و مواردی از این دست اشاره نمود (Lee et al. 2006, Harma 2003). در واقع بیماری‌های مختلف، ضعف و یا تفاوت بین گونه‌ها ممکن است باعث شود که سیگنال‌های صوتی منتشره از پرندگان در حوزه‌های زمان و فرکانس دارای ویژگی‌های متفاوتی باشند. از آنجا که این تفاوت‌ها بارز و قابل تشخیص هستند، بر اساس آن‌ها می‌توان انواع ارزیابی‌های مختلف را به عمل آورد. از این رو در سال‌های اخیر تجزیه و تحلیل صدای پرندگان به منظور انواع ارزیابی‌های مختلف مورد توجه قرار گرفته است (Catchpole, 1982), (Robertson et al., 2004), (Gaston and O'Neill, 2004). طبیعت سیگنال‌های صوتی باعث شده است که دارای نوفه^۱ فراوان باشند و آنالیز آنها را با مشکل مواجه کرده است. نمود این معضل در میان سیگنال‌های صوتی زیستی مانند صدای

حیوانات و پرندگان شدیدتر است. از این رو شناسایی و استخراج اطلاعات لازم از سیگنال‌های صوتی پرندگان به راحتی امکان‌پذیر نیست و روش‌های خاص خود را می‌طلبند. مهم‌ترین مانع بر سر استفاده از سیگنال‌های صدا در ارزیابی‌های مختلف از جانوران، تاثیرپذیری شدید آن از شرایط محیطی و نوفه است. یعنی جلوگیری از ورود نوفه به سامانه صدا برداری بسیار مشکل است. در این‌گونه موارد ابتدا تلاش می‌شود تا شرایط داده‌برداری به نحوی باشد که صداهای مزاحم و اضافه در محیط وجود نداشته باشند. بعد از داده‌برداری نیز با روش‌های مختلف (مانند آنالیز موجک نوفه‌زدا) به نویززدایی از سیگنال‌ها می‌پردازند. در مجموع به دو دلیل نخست دشوار بودن داده‌برداری دقیق و قابل اطمینان و دیگری پیچیده بودن روش‌های تجزیه و تحلیل سیگنال‌ها، هنوز استفاده از سیگنال‌های صدا در ارزیابی‌های مختلف کاملاً صنعتی و تجاری نشده است.

در تحقیقی سامانه‌ای خودکار را به منظور تشخیص و طبقه‌بندی صدای پرندگان و دوزیستان طراحی و به کار گرفتند. هدف اصلی این پژوهش تشخیص صدای پرندگان از دوزیستان بود. به عنوان مطالعه موردی، ۹ گونه قورباغه و ۳ نوع پرند مورد بررسی قرار گرفتند. در این پژوهش از سه روش مختلف

* نویسنده مسئول: ah_banakar@modares.ac.ir

پژوهش نیز از صدای پرندگان جهت تشخیص زیرگونه‌ی آنها استفاده شده است (King and West 1977). یک راهبرد کلی به منظور تجزیه و تحلیل سیگنال‌های صدای پرندگان توسط (Miller 1979) ارائه شده است. در این پژوهش صدای پرندگان و راهکارهای پیشنهادی به منظور نوفه‌زدایی، پردازش و نحوه‌ی تشخیص آنها مورد بررسی قرار گرفته است. مشخصات مشترک صدای پرندگان و خفاش‌ها در پژوهش دیگری مورد بررسی قرار گرفته است. این پژوهش تلاشی است جهت اینکه ویژگی‌های مشترک فرکانسی بین صداها باعث گمراهی و برآورد اشتباه در اطلاعات مربوط به یک پرنده نشود (Carr and Soares 2007). در پژوهشی نیز ارتباط تنوع زیستی پرندگان و حالات مختلف آنها با صدایی که از خود منتشر می‌کنند بررسی شده است. در این پژوهش ویژگی‌های رفتاری و مورفولوژیکی گونه‌های مختلف و تاثیر آنها بر صدای منتشره از پرندگان مورد تجزیه و تحلیل قرار گرفته است. همچنین از طریق صدای پرندگان به تخمین وزن آنها نیز مبادرت شده است (Gasc et al., 2013).

در پژوهش حاضر سامانه‌ای هوشمند به منظور تشخیص و طبقه‌بندی اردک‌های سالم از پرندگان بیمار بر اساس صدای آنها طراحی و مورد استفاده قرار گرفته است. از این سامانه به منظور تشخیص و طبقه‌بندی اردک‌های سالم و بیمار از یکدیگر استفاده شد. بدین منظور ابتدا تعدادی اردک سالم و بیمار انتخاب و صدای آنها توسط یک میکروفن ضبط شد. سیگنال‌های تحصیل شده توسط یک سامانه تحصیل داده^۵ ثبت و به رایانه انتقال یافتند و سپس به وسیله‌ی نرم‌افزار متلب^۶ خوانده شدند. در این پژوهش ابتدا سیگنال‌های صدا در حوزه‌ی زمان پردازش شدند. سپس توسط تبدیل سریع فوری^۷ به حوزه فرکانس انتقال یافتند.

پس از ضبط و خوانش سیگنال‌ها در نرم‌افزار، در مرحله‌ی داده کاوی^۸ می‌بایست اطلاعات لازم از آنها استخراج شود. این اطلاعات از طریق استخراج توابع ویژگی^۹ از سیگنال‌ها اقتباس می‌شوند. توابع ویژگی بیان‌گر رفتار سیگنال‌ها و عامل مهمی در شناسایی آنها به شمار می‌روند. در این مرحله تعداد پنج تابع ویژگی از سیگنال‌های حوزه‌ی زمان و فرکانس استخراج شد. از این توابع ویژگی به عنوان ورودی طبقه‌بندهای شبکه عصبی مصنوعی (ANN)^{۱۰} و ماشین بردار پشتیبان (SVM)^۱ استفاده

طبقه بندی ماشین بردار پشتیبان^۱، درخت تصمیم^۲ و آنالیز جداسازی خطی^۳ استفاده شد. ساختار این سامانه‌ها بر اساس آنالیز صدای پرندگان در حوزه‌ی زمان آموزش و توسط داده‌های جدید آزمون شد. دقت طبقه‌بندی و شناسایی سیگنال‌ها برای ماشین بردار پشتیبان ۹۴ درصد، درخت تصمیم ۸۹ درصد و آنالیز جداسازی خطی ۷۱ درصد به دست آمد (Acevedo, Corrada-Bravo et al. 2009). این نتایج حاکی از برتری روش-های هوشمند در تشخیص سیگنال‌های زیستی نوفه‌ای و ناپایدار است.

برای پایش جمعیت پرندگان در محیط زیست از تخمین جمعیت کلنی‌های پرندگان بر اساس صدای توده‌های آنها استفاده شده است (Bardeli, Wolff et al. 2010). در این تحقیق در گام نخست به منظور جداسازی صدای پرندگان از سایر حیوانات از آنالیز فرکانسی سیگنال‌های تحصیل شده استفاده شد. سپس بر اساس ویژگی‌های سیگنال‌های نوفه زدایی شده، جمعیت توده‌های پرندگان تخمین زده شد. نتایج این پژوهش ابتدا در تشخیص صدای پرندگان از سایر گونه‌ها و سپس در تخمین تعداد گله‌ها و توده‌های پرندگان در حیات وحش به کار گرفته شد.

در مطالعه‌ی ای به منظور تشخیص و طبقه‌بندی گونه‌های مختلف پرندگان بر اساس صدای آنها، توابع ویژگی مختلفی از سیگنال‌های صوتی استخراج و مورد پردازش قرار گرفت. نتایج این پژوهش نشان داد که در طبیعت بر اساس صدای منتشره از پرندگان می‌توان گونه و جنس آنها را شناسایی نمود. دقت میانگین سامانه‌ی طراحی شده در این پژوهش در تشخیص گونه‌های مختلف پرندگان حدود ۸۲ درصد برآورد شد (Kasten, McKinley et al. 2010). در پژوهشی دیگر به شناسایی محل تردد و زندگی ۱۰ گونه از پرندگان/ندمیک نامیبیایی بر اساس صدای خاص هریک از آنها پرداخته شده است. در این تحقیق ابتدا به شناسایی نوع پرنده در محل‌های مختلف بر اساس مشخصات صدایی آن گونه و سپس به تخمین تعداد پرندگان هر توده بر اساس شدت صدای آن توده پرداخته شد. بدین ترتیب محل تردد و زندگی این پرندگان ردیابی و تعداد جمعیت توده-های مختلف آنان تخمین زده شد (Jarvis and Robertson 1999). در پژوهش دیگری به شناسایی زیر گونه‌های مختلف یک نوع پرنده^۴ در آمریکای شمالی پرداخته شده است. در این

5. Data acquisition system

6. MATLAB

7. Fast Fourier Transform (FFT)

8. Data mining

9. Feature extraction

10. Artificial Neural Network (ANN)

1. Support Vector Machine (SVM)

2. Decision Tree

3. Linear discriminant Analysis (LDA)

4. Cowbird

تیمارها یکسان و کنترل شده بود. بدین ترتیب کنترل مناسبی روی شرایط داده برداری انجام شد. صدابرداری از اردک‌های بیمار و سالم توسط یک میکروفن خزانی انجام شد. میکروفن توسط یک کارت صدا به رایانه متصل شد و بدین ترتیب سیگنال‌ها ذخیره شدند. نام و مشخصات این میکروفن در جدول (۱) آمده است.

جدول ۱- مشخصات میکروفن خزانی مورد استفاده در این پژوهش

مدل میکروفن	AKG- c 417
نوع حسگر	میکروفن خزانی پولاریزه
نرخ داده برداری	۴۰ کیلوهرتز
گستره فرکانسی	20 Hz- 20 KHz
حساسیت	10 mV/Pa
توانایی ثبت شدیدترین صدا	۱۲۶ دسی بل

پردازش سیگنال در حوزه فرکانس

سیگنال‌های صدا به علت آنکه در طول زمان دارای تغییرات هستند، الزاماً دارای نرخ تغییرات یا همان فرکانس نیز می‌باشند. در کاربردهای مختلف، یافتن فرکانس این سیگنال‌ها از اهمیت ویژه‌ای برخوردار است چرا که می‌تواند ابزاری بسیار کارآمد در تشخیص و طبقه‌بندی سیگنال‌ها باشد. بدیهی است که برای به دست آوردن این فرکانس‌ها به ابزار محاسباتی نیرومندی نیاز است.

تکنیک‌های پردازش سیگنال در این حوزه همگی بر انتقال سیگنال از حوزه‌ی زمان به حوزه فرکانس استوار هستند. مزیت پردازش سیگنال در حوزه‌ی فرکانس در مقایسه با سیگنال‌های حوزه‌ی زمان؛ تشخیص و طبقه‌بندی سریع‌تر، ساده‌تر و البته همراه با دقت بیشتر سیگنال‌هاست. در قرن نوزده میلادی جوزف فوریه نشان داد که هر تابع متناوب را می‌توان به صورت مجموعی نامتناهی از توابع پایه‌ی سینوس و کسینوس بازنویسی کرد. روش‌های فراوانی برای پردازش سیگنال در حوزه فرکانس معرفی شده‌اند اما تبدیل سریع فوریه رایج‌ترین و موثرترین روش پردازش سیگنال در این حوزه است (Bracewell & Bracewell, 1986). این روش شکل استاندارد شده و تعمیم یافته‌ی تبدیل پیوسته فوریه برای کاربردهای رایانه‌ای است. تبدیل فوریه با معادله‌ی زیر تعریف می‌گردد (Walker, 1996):

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j\omega t} dt, \text{ when } : \omega = 2\pi f \quad (\text{رابطه ۱})$$

در این فرمول t و f به ترتیب زمان و فرکانس هستند و $X(f)$ تبدیل فوریه‌ی سیگنال زمانی $x(t)$ می‌باشد. در هر مقدار f که حاصل انتگرال عددی بزرگ باشد، سیگنال x دارای یک

شد. از روش‌های ANN و SVM جهت شناسایی و طبقه‌بندی سیگنال‌های صدای اردک‌های سالم و بیمار استفاده شد. بدین ترتیب دقت سامانه‌ی هوشمند طراحی شده در طبقه‌بندی پرندگان بر اساس صدای آنها به دست آمد. در ادامه به تشریح روند اجرای مراحل مختلف پژوهش و نتایج به دست آمده پرداخته خواهد شد.

مواد و روش‌ها

میز آزمون و داده برداری

آزمایش‌ها و داده‌برداری‌های مربوط به این پژوهش در دو مجتمع پرورش طیور در شهرستان جویبار انجام شد. بدین منظور ۳۲ اردک سالم انتخاب شدند و سیگنال‌های صدای آنها ضبط شد. در انتخاب اردک‌های سالم تلاش شد تا جنس و اندازه آنها تقریباً یکسان و از دسته‌ی اردک‌های متوسط باشند. از هر کدام از اردک‌های سالم ۳ بار صدابرداری شد که از میان آنها یک سیگنال که دارای نوفه^۲ کمتری بود برای تجزیه و تحلیل انتخاب شد.

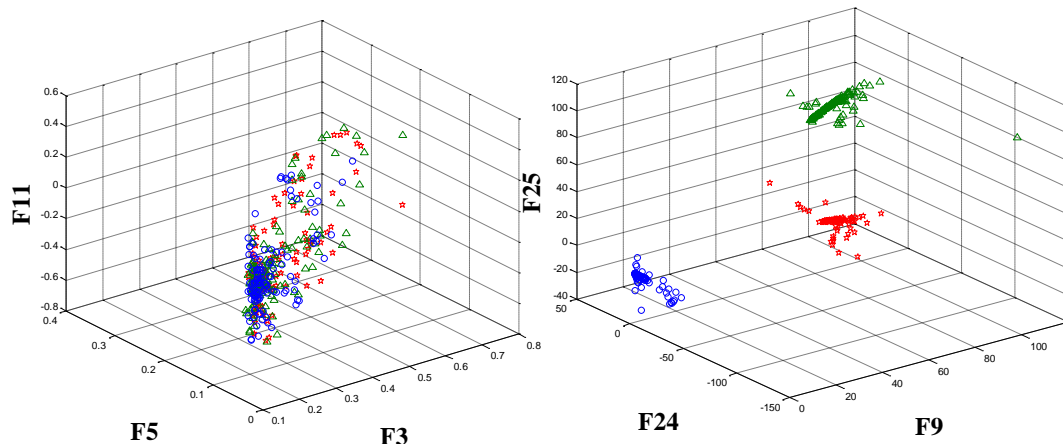
هر واحد پرورش طیور دارای تلفاتی است. در این پژوهش از اردک‌هایی که از سوی بخش پرورش طیور بیمار شناخته شده بودند و می‌بایست حذف می‌شدند، صدابرداری انجام شد. در طول دوره‌ی آزمایش‌های این پژوهش، ۱۷ اردک توسط فرد مسئول واحد به عنوان بیمار شناخته شده و نسبت به حذف آنها اقدام شد. از هریک از اردک‌های بیمار پیش از حذف آنها ۳ بار صدابرداری شد و از این ۳ تکرار نیز یک سیگنال که نسبت سیگنال به نوفه بیشتری داشت انتخاب شد. بدین ترتیب در مجموع ۴۹ سیگنال صدا برای مراحل بعدی مانند پردازش سیگنال و داده‌کاوی مورد استفاده قرار گرفت که از این میان ۳۲ سیگنال مربوط به اردک‌های سالم و ۱۷ سیگنال مربوط به اردک‌های بیمار بود. در هنگام آزمایش‌های صدابرداری حتماً باید توجه شود که نوفه به شدت کنترل شود و همچنین از تاثیر عوامل تاثیرگذار دیگر نیز جلوگیری به عمل آید. این موضوع به خصوص در مورد سیگنال صدای موجودات زنده از اهمیت بیشتری برخوردار است. در این پژوهش ابتدا تلاش شده است تا از ورود هرگونه نویز و صداهای غیر واقعی به سامانه داده برداری جلوگیری به عمل آید. در همین راستا صدای اردک در شرایط کاملاً غیر تنش‌زا و آرام ثبت شد. شرایط داده برداری اعم از نور، دما، رطوبت، مکان اندازه‌گیری صدا و غیره نیز برای تمام

1. Support Vector Machine
2. Noise

مولفه غالب فرکانسی در فرکانس f است.

داده کاوی و استخراج ویژگی

مقادیر خام سیگنال‌های حوزه‌ی زمان یا حوزه‌ی فرکانس نمی‌توانند به صورت مستقیم به عنوان ورودی طبقه‌بند مورد استفاده قرار گیرند. چرا که این مقادیر گروه بسیار بزرگی از داده‌های خام را در بر می‌گیرند و تعبیر ریاضی- فیزیکی خاصی نیز ندارند. به همین دلیل لازم است تا تعدادی از شاخص‌های سیگنال که دارای تعبیر ریاضی و فرمول خاصی هستند را استخراج کرده و برای مراحل بعدی که همانا شناسایی سیگنال است، از آنها بهره جست. این ویژگی‌ها در واقع توابعی هستند که بر روی سیگنال‌ها تعریف می‌شوند و هر یک معرف مناسبی برای بیان رفتار آنها هستند. شکل ۱ به خوبی اثر دو نوع استخراج ویژگی بر شناسایی سیگنال‌های ارتعاشی تحصیل شده



شکل ۱- تاثیر دو نوع استخراج ویژگی بر شناسایی سیگنال‌ها. سمت راست: یک استخراج ویژگی مناسب؛ سمت چپ: یک استخراج ویژگی نامناسب

در پژوهش حاضر ۵ ویژگی از سیگنال‌های صدای اردک‌ها استخراج شدند. توانایی و مفید بودن این ویژگی‌ها بر اساس منابع مختلف مورد تایید قرار گرفته است (Lei, He *et al.* 2008). جدول (۲) نام و فرمول مربوط به توابع ویژگی مورد استفاده در این پژوهش را نشان می‌دهد. در این جدول $x(n)$ سری زمانی سیگنال و N تعداد نقاط داده‌ها^۱ هستند.

شبکه عصبی مصنوعی

روش‌های فراوانی برای تشخیص و طبقه‌بندی سیگنال‌ها معرفی شده‌اند که هر یک به اقتضای شرایط حاکم بر مساله دارای کاربردهای خاص خود هستند و در موارد بسیاری با موفقیت به کار گرفته شده‌اند. از مهم‌ترین طبقه‌بندها می‌توان به منطق فازی^۲ (Ishibuchi, Nakashima *et al.* 1999)، شبکه عصبی

جدول ۲- ویژگی‌های استخراج شده از سیگنال‌های صدا

ردیف	نام ویژگی	فرمول
۱	میانگین	$T_1 = \frac{\sum_{n=1}^N x(n)}{N}$
۲	انحراف معیار	$T_2 = \sqrt{\frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}}$
۳	واریانس	$T_3 = \frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}$
۴	کورتسیس	$T_4 = \frac{\sum_{n=1}^N (x(n) - T_1)^4}{(N - 1)T_2^4}$
۵	ریشه‌ی میانگین مربعات	$T_5 = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$

1. Data point
2. Fuzzy Logic

از حالات مختلف یک جعبه‌دنده را نشان می‌دهد (Khazaei, 2012).

یک استخراج ویژگی خوب و خلاقانه می‌تواند به خوبی فضای داده‌های ورودی به طبقه‌بند را کاهش داده، باعث صرفه‌جویی در زمان و رسیدن به نتایج بهتر با محاسبات کمتر و در مجموع افزایش دقت عیب‌یابی شود. انتخاب تعداد کمی از ویژگی‌ها باعث می‌شود تا خواص و حالات یک سیگنال به خوبی برجسته نشود و در نتیجه طبقه‌بند نتواند بین دو سیگنال متفاوت تمایزی قائل شود. انتخاب تعداد فراوان توابع ویژگی نیز باعث می‌شود تا طبقه‌بند در اصطلاح سردرگم شود و مجدداً نتواند تفاوت بین دو گروه ویژگی استخراج شده از دو طبقه سیگنال را تشخیص دهد (Yang, Yang *et al.* 2003).

ماشین بردار پشتیبان

ماشین بردار پشتیبان یک روش بسیار نیرومند در تشخیص و طبقه‌بندی عیوب است و کاربردهای بسیار فراوانی در پایش وضعیت یافته است. ماشین بردار پشتیبان در بسیاری مواقع برتری‌های بزرگی نسبت به دیگر روش‌های هوش مصنوعی دارد. به عنوان مثال این طبقه‌بند نسبت به آشفتگی در عملکرد با افزایش تعداد ویژگی‌ها به خوبی مقاومت نشان می‌دهد (Hu et al., 2007). ماشین بردار پشتیبان را برای نخستین بار کورتس و وپنیک در سال ۱۹۹۵ میلادی بر پایه تئوری یادگیری آماری بنا نهادند. ایده‌ی محوری در این روش طبقه‌بندی، آن است که داده‌های هر کلاس را به عنوان یک مجموعه در فضای n بعدی ترسیم نموده، سپس با استفاده از یک ابر صفحه فرضی کلاس‌ها را از یکدیگر جدا نمود (Cortes & Vapnik., 1995).

فرض شود تعدادی داده‌ی آموزشی وجود داشته باشد، یک مجموعه از نقاط به فرم:

(رابطه ۲)

$D = \{(x_i, y_i) | x_i \in \mathbb{R}^p, y_i \in \{1, -1\}\} \quad i = 1, 2, \dots, N$
 که y_i می‌تواند ۱ یا -۱ باشد، که مشخص می‌کند نقطه x_i متعلق به چه کلاسی است. هر x_i یک بردار p بعدی است. مطلوب است جداکننده‌ی بیشینه حاشیه‌ی پیدا شود تا نقاطی که y_i آن‌ها برابر ۱ است از نقاطی که y_i آن‌ها -۱ است را جدا کند. هر ابرصفحه می‌تواند به صورت یک مجموعه از نقاط x که رابطه‌ی زیر را ارضا می‌کند، نوشته شود:

$$f(x) = w^T \cdot x + b = \sum_{j=1}^N w_j x_j + b = 0 \quad (\text{رابطه ۳})$$

بردار w یک بردار نرمال است. این بردار که بر ابرصفحه عمود است پارامتر $\frac{b}{w}$ آفت ابرصفحه از مبدأ در امتداد بردار نرمال w می‌باشد. می‌خواهیم w و b را طوری انتخاب کنیم که حاشیه یا فاصله‌ی بین ابرصفحه‌های موازی بیشینه شود به نحوی که ابرصفحه‌های موازی تا آنجا که می‌توانند از هم دور باشند و همچنان داده‌ها را بتوان جدا کرد. این ابرصفحه‌های موازی می‌توانند با معادله‌های زیر توصیف شوند:

$$w \cdot x_i + b \geq +1, y_i = +1 \quad (\text{رابطه ۴})$$

$$w \cdot x_i + b \leq -1, y_i = -1 \quad (\text{رابطه ۵})$$

توجه شود که اگر داده‌های آموزشی را بتوان به صورت خطی جدا کرد، می‌توان دو صفحه جداکننده را طوری انتخاب کرد که هیچ نقطه‌ای (داده‌ای) بین آن‌ها نباشد و سپس سعی شود که فاصله آن‌ها بیشینه باشد. با استفاده از هندسه، فاصله بین این دو ابرصفحه (پهنای حاشیه) را که برابر $\frac{2}{\|w\|}$ می‌باشد،

مصنوعی^۱ (Khazae, Ahmadi et al. 2013)، ماشین بردار پشتیبان^۲ (Salahshoor, Kordestani et al. 2010)، k امین نزدیک‌ترین همسایگی^۳ (Liao and Vemuri 2002) و غیره اشاره نمود. شبکه مصنوعی عصبی یکی از رایج‌ترین و پرکاربردترین روش‌های هوش مصنوعی در تشخیص و طبقه‌بندی سیگنال‌هاست (Banakar and KARIMI AKANDI, 2012). در این پژوهش نیز از این روش به منظور طبقه‌بندی سیگنال‌های صدای پرندگان استفاده شد.

به منظور اجرای یک فرآیند طبقه‌بندی با استفاده از شبکه‌های عصبی، اولین گام انتخاب ابعاد شبکه است. شبکه‌های عصبی همواره با سه لایه تعریف می‌شوند: لایه ورودی، لایه میانی یا لایه پنهان و لایه خروجی. در لایه ورودی باید به تعداد ابعاد هر الگوی ورودی یک نرون قرار داده شود؛ بنابراین اندازه لایه ورودی را بعد داده‌های ورودی تعیین می‌کند. در لایه خروجی نیز باید به تعداد طبقات، نرون وجود داشته باشد. در مورد تعداد نرون‌های لایه‌ی میانی قانون و مبنای خاصی وجود ندارد و معمولاً با روش سعی و خطا بهترین تعداد نرون انتخاب می‌شود (Banakar and Azeem 2008). همچنین به طور کلی میزان داده‌های آموزش شبکه نباید از ۷۵ درصد کل داده‌ها بیشتر باشد. در این پژوهش ۶۰ درصد داده‌ها به آموزش و مابقی آنها برای آزمون شبکه اختصاص یافته‌اند.

در این تحقیق از شبکه عصبی پیشخور دولایه^۴ و الگوریتم آموزش لوبنبرگ-مارکواریت^۵ استفاده گردید. تعداد نرون‌های ورودی شبکه عصبی به تعداد توابع ویژگی استخراج شده از داده‌ها یعنی ۵ عدد تعیین شد. همچنین لایه‌ی خروجی نیز با ۲ نرون تعریف شد که معرف دو حالت ممکن برای سیگنال‌هاست: الف- سیگنال‌های مربوط به پرندگان بیمار؛ ب- سیگنال‌های مربوط به پرندگان سالم. اما مهم‌ترین لایه در طراحی شبکه عصبی لایه میانی (لایه پنهان) است. به منظور نیل به بهترین عملکرد شبکه، تعداد مختلف نرون‌های لایه میانی از ۱ تا ۱۰ مورد آزمایش قرار گرفت که از این میان بهترین نتایج در حوزه زمان و فرکانس به ترتیب در شبکه‌ای با ۶ و ۲ نرون در لایه میانی به دست آمد. در نهایت با توجه به توضیحات داده شده ساختار بهینه شبکه عصبی طراحی شده برای تحلیل سیگنال‌های حوزه‌ی زمان ۲*۶*۵ و برای طبقه‌بندی سیگنال‌های حوزه‌ی فرکانس ۲*۲*۵ انتخاب شد.

1. Artificial Neural Network (ANN)
2. Support Vector Machine (SVM)
3. K- nearest neighbor (KNN)
4. FeedForward Neural Network
5. Levenberg_Marquardt Learning Algorithm

نویسی درجه دو^۱ استاندارد حل شود. جواب به صورت زیر خواهد شد:

$$w = \sum_{i=1}^N \alpha_i x_i y_i; \quad \& b = 1 - w \cdot x_i \quad (\text{رابطه ۱۵})$$

تنها تعداد کمی از α_i ها می توانند بزرگ تر از صفر باشند که این تعداد دقیقاً بردارهای پشتیبان x_i هستند که روی حاشیه قرار دارند و رابطه ی (۶) را ارضا می کنند. همچنین بردارهای پشتیبان رابطه ی زیر را نیز ارضا می کنند:

$$w \cdot x_i + b = y_i \leftrightarrow b = w \cdot x_i - y_i \quad (\text{رابطه ۱۶})$$

نتایج و بحث

سیگنال های حوزه ی زمان

در این پژوهش صدای اردک های سالم و بیمار ابتدا توسط یک میکروفن ثبت و سپس سیگنال های آنالوگ تحصیل شده توسط نرم افزار متلب خوانده و به صورت یک سری زمانی درآمد. شکل های ۲ و ۳ یک نمونه از سیگنال های صدای تحصیل شده از پرندگان را در حالات بیمار و سالم نشان می دهند.

با نگاهی گذرا به سیگنال های نشان داده شده می توان تفاوت های خاص بین صدای این دو دسته از اردک ها را مشاهده نمود. نخست آنکه شدت صدای اردک های سالم به صورت میانگین از صدای اردک های ضعیف و بیمار بیشتر است. دیگر تفاوتی که از روی نمودارها به چشم می خورد یکنواختی بیشتر صدای اردک های سالم نسبت به اردک های بیمار است؛ یعنی صدای اردک های سالم دارای شدت و یکنواختی بیشتری هستند در حالی که سیگنال های صدای اردک های بیمار موج و ضعیف تر است. البته صدای شدید در سیگنال های مربوط به اردک های بیمار نیز مشاهده می شود اما این شدت مقطعی است و بیشتر به صورت یک نویز با فرکانس بالا در میان صدای اصلی با فرکانس کمتر خود را نشان می دهد. تفاوت های یاد شده هم بر اساس دانسته های قبلی قابل توجیه و پذیرفتنی است و هم در بخش نتایج مربوط به استخراج ویژگی نیز مورد تایید قرار گرفته اند (Al-Balushi and Samanta 2002).

سیگنال های حوزه ی فرکانس

در این پژوهش سیگنال های تحصیل شده در حوزه ی زمان توسط تبدیل سریع فوریه به حوزه ی فرکانس انتقال یافتند. انتقال سیگنال ها به حوزه ی فرکانس باعث نویز زدایی و همچنین در اختیار داشتن اطلاعات فرکانسی صدای پرندگان

پیدا می شود. بنابراین می بایست $\|w\|$ را کمینه و از قرار گرفتن نقاط در حاشیه جلوگیری کرد. معادلات (۴) و (۵) را می توان برای هر i به صورت زیر نوشت:

$$y_i(w \cdot x_i + b) \geq 1 \quad (\text{رابطه ۶})$$

حل مسئله بهینه سازی $\frac{2}{\|w\|}$ مشکل است، زیرا به $\|w\|$ بستگی دارد. می توان معادله قبل را با توجه به رابطه ی (۷) بدون تغییر راه حل، جایگزین کرد.

$$\|w\| = \frac{1}{2} \|w\|^2 \quad (\text{رابطه ۷})$$

بنابراین، ابرصفحه ی بهینه با رابطه ی بهینه سازی کمینه

$$\text{کردن } \frac{1}{2} \|w\|^2 \text{ به شرط زیر به دست می آید:}$$

$$y_i(w \cdot x_i + b) \geq 1 \quad i = 1, 2, \dots, N \quad (\text{رابطه ۸})$$

رابطه ی (۸) می تواند با ضرایب لاگرانژ غیرمنفی به صورت زیر بیان شود:

$$(\text{رابطه ۹})$$

$$L(\vec{w}, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i (y_i(w^T x_i + b) - 1)$$

می بایست $L(\vec{w}, b, a)$ نسبت به w و b کمینه شود:

$$\frac{\partial}{\partial w} L(\vec{w}, b, a) = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i x_i y_i \quad (\text{رابطه ۱۰})$$

$$\frac{\partial}{\partial b} L(\vec{w}, b, a) = 0 \Rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (\text{رابطه ۱۱})$$

اکنون می خواهیم با استفاده از رابطه ی $\|w\|^2 = w \cdot w$ و جایگزینی روابط (۱۰) و (۱۱) که از فرم دوگان مسئله بهینه سازی SVM به دست آمدند، مسئله بهینه سازی بیشینه کردن $L(\vec{w}, b, a)$ نسبت به α_i را حل کرد:

$$(\text{رابطه ۱۲})$$

$$L(\vec{w}, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i (y_i(w^T x_i + b) - 1) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i w^T x_i y_i - b \sum_{i=1}^N \alpha_i y_i + \sum_{i=1}^N \alpha_i$$

بنابراین:

$$(\text{رابطه ۱۳})$$

$$L(\vec{w}, b, a) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j)$$

به شرطی که:


$$(\text{رابطه ۱۴})$$

$$\sum_{i=1}^N \alpha_i y_i = 0, \quad i = 1, 2, \dots, N, \quad \alpha_i \geq 0$$


اکنون این مسئله می تواند توسط تکنیک های برنامه

دسترس قرار می‌گیرند. شکل‌های ۴ و ۵ به ترتیب یک نمونه از سیگنال‌های صدای پرندگان سالم و بیمار را در حوزه‌ی فرکانس نشان می‌دهند.


می‌شود (Wang, 2013). بدین ترتیب بسیاری از تفاوت‌های صدای پرندگان که از طریق آنالیز سیگنال‌های حوزه‌ی زمان قابل تشخیص نیستند، از طریق آنالیز سیگنال‌های فرکانسی در




شکل ۲- سیگنال صدای اردک‌های سالم



شکل ۳- سیگنال صدای اردک‌های بیمار



شکل ۴- سیگنال صدای اردک سالم در حوزه‌ی فرکانس



شکل ۵- سیگنال صدای اردک بیمار در حوزه فرکانس
تایید می‌کند.

نتایج داده کاوی

توابع ویژگی استخراج شده از سیگنال‌ها در بخش قبل معرفی شدند و در این بخش به تشریح نتایج به دست آمده از داده‌کاوی سیگنال‌های حوزه‌ی زمان و فرکانس پرداخته می‌شود. در جدول‌های (۳) و (۴) مقایسه‌ای نسبی بین مقادیر ویژگی‌های استخراج شده از سیگنال‌های حوزه‌ی زمان و فرکانس انجام شده است. در این جدول‌ها مقدار میانگین ویژگی‌ها مد نظر قرار گرفته است.

از میان ویژگی‌های استخراج شده دو ویژگی واریانس و انحراف از معیار نشان دهنده‌ی میزان پراکندگی سیگنال هستند. در واقع هرچه واریانس و انحراف از معیار یک سیگنال بیشتر باشد یعنی آن سیگنال غیر یکنواخت و مواج‌تر است (Engel, Gilmartin *et al.* 2000). مقادیر به دست آمده نشان می‌دهد که واریانس و انحراف از معیار سیگنال‌های صدای پرندگان بیمار بیشتر از پرندگان سالم است. در واقع این مقادیر نشان می‌دهند که صدای پرندگان بیمار نسبت به پرندگان سالم، دارای پراکندگی بیشتر، مغشوش‌تر، غیر یکنواخت‌تر و ناپایدارتر هستند (McKay, Fujinaga *et al.* 2005). دو ویژگی میانگین و ریشه‌ی میانگین مربعات توابعی هستند که شدت و کمیت مقادیر یک سیگنال را نشان می‌دهند. با نگاهی به جدول‌های (۳) و (۴) می‌توان دید که میانگین و ریشه‌ی میانگین مربعات سیگنال‌های صدای اردک‌های سالم از سیگنال‌های صدای اردک‌های بیمار بیشتر است. این مقادیر به وضوح بیان می‌دارند که شدت صدای پرندگان سالم بسیار بیشتر و البته یکنواخت‌تر از صدای پرندگان بیمار است (Nowak, Wagoner *et al.* 1997). بنابراین می‌توان گفت که نتایج به دست آمده در مرحله استخراج ویژگی، نتایج شهودی حاصل از نمایش سیگنال‌ها را

جدول ۳- مقادیر به دست آمده از سیگنال‌های زمان

مقدار ویژگی		نام ویژگی
اردک سالم	اردک بیمار	
---	+ / ۰.۵۴	واریانس
----	+ / ۰.۲۸	انحراف از معیار
+ / ۰.۵۰	----	میانگین
+ / ۰.۲۵	----	ریشه‌ی میانگین مربعات

جدول ۴- مقادیر به دست آمده از سیگنال‌های فرکانس

مقدار ویژگی		نام ویژگی
اردک سالم	اردک بیمار	
---	+ / ۰.۹۶	واریانس
----	+ / ۰.۵۵	انحراف از معیار
+ / ۰.۲۹	----	میانگین
+ / ۰.۴۸	----	ریشه‌ی میانگین مربعات

شناسایی سیگنال‌ها در حوزه‌ی زمان به کمک شبکه عصبی مصنوعی

تمرکز اصلی این پژوهش بر تشخیص و طبقه‌بندی سیگنال‌های صدای پرندگان بیمار و سالم است. همانگونه که گفته شد به منظور شناسایی و طبقه‌بندی سیگنال‌ها از طبقه‌بند شبکه عصبی مصنوعی استفاده شد. تعداد کل داده‌ها در این پژوهش ۴۹ سیگنال صوتی بود. از این تعداد داده، ۲۸ سیگنال (تقریباً ۶۰ درصد داده‌ها) به منظور آموزش و یافتن ساختار و وزن‌های بهینه بین نرون‌ها به شبکه داده شدند. در این مرحله دقت شبکه در داده‌های آموزش ۹۱/۷ درصد به دست آمد. سپس ۲۱ سیگنال باقیمانده (تقریباً ۴۰ درصد داده‌ها) به منظور آزمون

دقت شبکه در تشخیص و طبقه‌بندی پرندگان از طریق آنالیز سیگنال صدای آنها در حوزه‌ی فرکانس نیز به دست آید. تعداد و تقسیم بندی نمونه‌ها در حوزه‌ی فرکانس نیز مانند حوزه‌ی زمان انتخاب شد. دقت شبکه عصبی مصنوعی در تشخیص و طبقه‌بندی پرندگان در داده‌های آموزش و آزمون به ترتیب ۹۲/۲ درصد و ۸۲/۱ درصد به دست آمد. نتایج نشان می‌دهد که دقت تشخیص صدای پرندگان بیمار و سالم با استفاده از داده‌های حوزه‌ی فرکانس با دقت بیشتری همراه بوده است (Chedad, Moshou *et al.* 2001). جدول‌های (۷) و (۸) به ترتیب ماتریس اغتشاش عملکرد شبکه عصبی در تشخیص صدای پرندگان بیمار و سالم بر پایه‌ی سیگنال‌های حوزه‌ی فرکانس را نشان می‌دهند. در جدول (۷) مشاهده می‌شود که شبکه عصبی از میان هجده پرنده‌ی سالم، هفده مورد را به درستی سالم و یکی را به اشتباه بیمار تشخیص داده است. همچنین از میان ۱۰ پرنده‌ی بیمار یک مورد را به اشتباه در طبقه‌ی پرندگان سالم جای داده است. با توجه به جدول (۸) نیز می‌توان دید که عملکرد شبکه در تحلیل داده‌های حوزه‌ی فرکانس بهبود یافته است. چرا که از میان ۱۴ اردک سالم، سه اردک را بیمار تشخیص داده است. این در حالی است که در طبقه‌بندی بر اساس داده‌های حوزه‌ی زمان، از ۱۴ پرنده‌ی سالم، ۵ مورد را بیمار تشخیص داده بود.

با نگاهی به جدول‌های (۵) و (۶) به روشنی پیداست که اگرچه عملکرد شبکه در تشخیص پرندگان بیمار بر اساس سیگنال‌های حوزه‌ی زمان خوب بوده است، اما در تشخیص پرندگان سالم با دقت کمتری عمل نموده است. از آنجا که هدف این پژوهش تشخیص پرندگان بیمار بوده است، دقت‌های به دست آمده قابل قبول می‌باشند. بنابراین باید سامانه‌ی هوشمند به نحوی طراحی شود که بتواند با دقت مناسبی پرندگان سالم را نیز به خوبی تشخیص دهد. با نگاهی به جدول‌های (۷) و (۸) می‌توان دریافت که با استفاده از اطلاعات به دست آمده از داده‌کاو سیگنال‌های فرکانسی، دقت شبکه عصبی هم به صورت میانگین و هم در تشخیص پرندگان سالم نیز افزایش یافته است. این نتایج حاکی از آن است که استفاده از آنالیز فرکانسی صدای پرندگان در تشخیص بیماری‌های آنان مفیدتر است (Exadaktylos, Silva *et al.* 2008).

شناسایی سیگنال‌ها در حوزه‌ی زمان به کمک ماشین بردار پشتیبان در این تحقیق، از روش ماشین بردار پشتیبان نیز به منظور تشخیص و طبقه‌بندی سیگنال‌های صدا استفاده شد. بهترین

شبکه و یافتن توانایی آن در تمایز بین سیگنال‌ها به شبکه وارد شدند. در این مرحله شبکه عصبی بر اساس ویژگی‌های استخراج شده از سیگنال‌های صدای پرندگان در حوزه‌ی زمان توانست با دقت ۷۵ درصد پرندگان بیمار و سالم را شناسایی کرده و طبقه‌بندی نماید. جدول (۵) و جدول (۶) به ترتیب ماتریس اغتشاش دقت شبکه عصبی مصنوعی در داده‌های آموزش و آزمون را نشان می‌دهند. در این جداول تعداد نمونه‌ها و نوع تصمیمات شبکه عصبی دیده می‌شود. با توجه به جدول (۵) مشاهده می‌شود که شبکه عصبی از میان هجده اردک سالم، پانزده عدد را به درستی طبقه‌بندی کرده است. همچنین شبکه هر ده اردک بیمار را به درستی در طبقه‌ی بیمار جای داده است.

جدول (۶) عملکرد شبکه عصبی در داده‌های آزمون را نشان می‌دهد. همانگونه که در این جدول پیداست، شبکه عصبی از میان چهارده اردک سالم، ۵ مورد را به غلط بیمار تشخیص داده است که این بدترین عملکرد شبکه در تحلیل داده‌های این پژوهش بوده است. بنابراین شبکه در تشخیص پرندگان بیمار بهتر عمل کرده و از ۷ اردک بیمار تنها یکی را به اشتباه سالم نامیده است.

جدول ۵- ماتریس اغتشاش شبکه عصبی در داده‌های آموزش- حوزه‌ی زمان

		خروجی شبکه عصبی		دقت میانگین
حالت واقعی	حالت پیش‌بینی	سالم	بیمار	
سالم	سالم	۱۵	۳	۸۳/۳٪
سالم	بیمار	۰	۱۰	۱۰۰٪
		دقت میانگین: ۹۱/۷٪		

جدول ۶- ماتریس اغتشاش شبکه عصبی در داده‌های آزمون- حوزه-ی زمان

		خروجی شبکه عصبی		دقت میانگین
حالت واقعی	حالت پیش‌بینی	سالم	بیمار	
سالم	سالم	۹	۵	۶۴/۲٪
سالم	بیمار	۱	۶	۸۵/۷٪
		دقت میانگین: ۷۵٪		

شناسایی سیگنال‌ها در حوزه‌ی فرکانس به کمک شبکه عصبی مصنوعی در این مرحله ویژگی‌های اقتباس شده از سیگنال‌های صدای پرندگان در حوزه‌ی فرکانس، به شبکه عصبی خوراندند تا

شناسایی سیگنال‌ها در حوزه‌ی فرکانس به کمک ماشین بردار پشتیبان

در این مرحله ویژگی‌های استخراج شده از سیگنال‌های حوزه‌ی فرکانس به عنوان ورودی طبقه‌بند ماشین بردار پشتیبان به کار گرفته شدند. جدول (۱۱) دقت این روش در تشخیص و طبقه‌بندی داده‌های آموزش در حوزه‌ی فرکانس را نشان می‌دهد. جدول (۱۲) نیز دقت ماشین بردار پشتیبان در تشخیص داده‌های آزمون در حوزه‌ی فرکانس را نشان می‌دهد. با دقت در جدول‌های (۱۱) و (۱۲) می‌توان دریافت که دقت روش SVM در دسته‌بندی سیگنال‌های حوزه‌ی فرکانس بیشتر از سیگنال‌های حوزه‌ی زمان است. این نتیجه در مورد روش شبکه عصبی نیز صادق است. یعنی با مقایسه جدول‌های (۶) و (۸) می‌توان مشاهده نمود که دقت شبکه عصبی در طبقه‌بندی سیگنال‌های حوزه‌ی فرکانس بیشتر از سیگنال‌های حوزه‌ی زمان است. جدول (۱۳) مقایسه‌ای بین دقت‌های به دست آمده بر اساس سیگنال‌های مختلف و روش‌های مختلف را نشان می‌دهد. با دقت در جدول (۱۳) می‌توان دو نتیجه‌گیری کلی را بیان نمود: نخست آن که به صورت کلی دقت طبقه‌بندی با استفاده از سیگنال‌های حوزه‌ی فرکانس بیشتر از سیگنال‌های حوزه‌ی زمان است؛ و دیگر آنکه در این مطالعه موردی دقت طبقه‌بند ماشین بردار پشتیبان بیشتر از دقت شبکه عصبی است.

جدول ۱۱- دقت طبقه‌بند ماشین بردار پشتیبان در داده‌های آموزش و بر اساس سیگنال‌های حوزه‌ی فرکانس

خروجی SVM			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۸	۰	٪۱۰۰
بیمار	۱	۹	٪۹۰
دقت میانگین: ٪۹۵			

جدول ۱۲- دقت طبقه‌بند ماشین بردار پشتیبان در داده‌های آزمون و بر اساس سیگنال‌های حوزه‌ی فرکانس

خروجی SVM			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۲	۲	٪۸۵/۷
بیمار	۰	۷	٪۱۰۰
دقت میانگین: ٪۹۲/۸			

نتایج با استفاده از تابع کرنل پایه شعاعی و مقدار بهینه $\sigma=0.1$ بود. جدول (۹) و (۱۰) به ترتیب دقت روش ماشین بردار پشتیبان در تشخیص پرندگان بیمار و سالم بر اساس صدای آنها برای داده‌های آموزش و آزمون را نشان می‌دهد.

با مقایسه جدول‌های (۵) و (۹) می‌توان دریافت که دقت روش ماشین بردار پشتیبان در داده‌های آموزش و بر اساس سیگنال‌های حوزه‌ی زمان از دقت شبکه عصبی بیشتر بوده است. همچنین با دقت در جدول‌های (۶) و (۱۰) مشاهده می‌شود که دقت طبقه‌بند ماشین بردار پشتیبان در داده‌های آزمون سیگنال‌های زمانی نیز نسبت به شبکه عصبی بیش از ۱۰ درصد افزایش یافته است.

جدول ۷- ماتریس اغتشاش شبکه عصبی در داده‌های آموزش- حوزه‌ی فرکانس

خروجی شبکه عصبی			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۷	۱	٪۹۴/۴
بیمار	۱	۹	٪۹۰
دقت میانگین: ٪۹۲/۲			

جدول ۸- ماتریس اغتشاش شبکه عصبی در داده‌های آزمون- حوزه‌ی فرکانس

خروجی شبکه عصبی			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۱	۳	٪۷۸/۶
بیمار	۱	۶	٪۸۵/۷
دقت میانگین: ٪۸۲/۱			

جدول ۹- دقت طبقه‌بند ماشین بردار پشتیبان در داده‌های آموزش و بر اساس سیگنال‌های حوزه‌ی زمان

خروجی SVM			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۸	۰	٪۱۰۰
بیمار	۱	۹	٪۹۰
دقت میانگین: ٪۹۵			

جدول ۱۰- دقت طبقه‌بند ماشین بردار پشتیبان در داده‌های آزمون و بر اساس سیگنال‌های حوزه‌ی زمان

خروجی SVM			
طبقه واقعی	سالم	بیمار	دقت (%)
سالم	۱۰	۴	٪۷۱/۴
بیمار	۰	۷	٪۱۰۰
دقت میانگین: ٪۸۵/۷			

جدول ۱۳- مقایسه دقت‌های به دست آمده با استفاده از روش‌های مختلف

دقت شبکه عصبی مصنوعی		دقت ماشین بردار پشتیبان		روش
داده‌های آموزش	داده‌های آزمون	داده‌های آموزش	داده‌های آزمون	نوع داده‌ها
٪ ۷۵	٪ ۹۱/۷	٪ ۸۵/۷	٪ ۹۵	سیگنال‌های حوزه‌ی زمان
٪ ۸۲/۱	٪ ۹۴/۴	٪ ۹۲/۸	٪ ۹۵	سیگنال‌های حوزه‌ی فرکانس

نتیجه‌گیری کلی

طبقه‌بندی کند. طبقه‌بند ماشین بردار پشتیبان بر اساس سیگنال‌های حوزه‌ی زمان و در داده‌های آموزش و آزمون به ترتیب با دقت ۹۵ و ۸۵/۷ درصد توانست اردک‌های بیمار و سالم را تشخیص دهد. همچنین این طبقه‌بند بر اساس سیگنال‌های حوزه‌ی فرکانس و در داده‌های آموزش و آزمون به ترتیب با دقت ۹۵ و ۹۲/۸ درصد توانست اردک‌های بیمار و سالم را طبقه‌بندی کند. نتایج این پژوهش تاکید می‌کنند که روش ماشین بردار پشتیبان در طبقه‌بندی سیگنال‌های صدای اردک‌ها بهتر از روش شبکه عصبی مصنوعی عمل کرده است. همچنین تحلیل فرکانسی سیگنال‌های صدا موثرتر و دقیق‌تر از تحلیل سیگنال‌ها در حوزه زمان است. نتایج این پژوهش نشان می‌دهند که استفاده از روش‌های هوشمند به منظور پایش سلامت پرندگان مفید و کاربردی است. نتایج این پژوهش می‌تواند در تشخیص بیماری‌های پرندگان موثر واقع شود و روش مناسبی برای پایش سلامت آنها در واحدهای پرورش پرندگان باشد.

در این مقاله سامانه‌ای هوشمند جهت شناسایی و طبقه‌بندی اردک‌های بیمار و سالم بر اساس صدایی که ایجاد می‌کنند، طراحی شده است. در این سامانه سیگنال‌های صدای پرندگان به صورت جداگانه در حوزه‌ی زمان و حوزه‌ی فرکانس مورد تجزیه و تحلیل قرار گرفتند. در مرحله‌ی داده کاوی ۵ ویژگی مهم از سیگنال‌های صدای هر دو گروه استخراج شد. این توابع به عنوان ورودی طبقه‌بند شبکه عصبی مصنوعی مورد استفاده قرار گرفتند تا دقت سامانه در شناسایی اردک‌های بیمار و سالم از یکدیگر به دست آید. دقت شبکه عصبی مصنوعی در تشخیص و طبقه‌بندی پرندگان بر اساس سیگنال‌های حوزه‌ی زمان برای داده‌های آموزش و آزمون به ترتیب ۹۱،۷ و ۷۵ درصد به دست آمد. همچنین شبکه عصبی با استفاده از ویژگی‌های مستخرج از سیگنال‌های حوزه‌ی فرکانس توانست پرندگان بیمار و سالم را با ۹۴/۴ و ۸۲/۱ درصد در آموزش و آزمون

REFERENCES

- Acevedo, M. A., Corrada-Bravo, C. J., Corrada-Bravo, H., Villanueva-Rivera, L. J., and Aide, T. M. (2009). Automated classification of bird and amphibian calls using machine learning: A comparison of methods. *Ecological Informatics*, 4(4), 206-214.
- Al-Balushi, K. & Samanta, B. (2002). Gear fault diagnosis using energy-based features of acoustic emission signals. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 216(3), 249-263.
- Banakar, A. & Azeem, M. F. (2008). Artificial wavelet neural network and its application in neuro-fuzzy models. *Applied Soft Computing*, 8(4), 1463-1485.
- Banakar, A. & Karimi Akandi, S. (2012). a comparison of mathematical and artificial neural network modeling for rosa petals using hot air drying method. *international journal of computational intelligence and applications*, 11(02), 1-14.
- Bardeli, R., Wolff, D., Kurth, F., Koch, M., Tauchert, K. H., & Frommolt, K. H. (2010). Detecting bird sounds in a complex acoustic environment and application to bioacoustic monitoring. *Pattern Recognition Letters*, 31(12), 1524-1534.
- Bracewell, R. N., & Bracewell, R. N. (1986). *The Fourier transform and its applications* (Vol. 31999). McGraw-Hill New York.
- Catchpole, C. K. (1982). The Evolution of Bird Sounds in Relation to Mating and Spacing Behavior. Pages 297-319. *Acoustic Communication in Birds*. San Diego: Academic Press
- Carr, C. E., & Soares, D. (2007). Shared Features of the Auditory System of Birds and Mammals. *Evolution of Nervous Systems*. H. K. Editor-in-Chief: Jon. Oxford, Academic Press: 443-457.
- Chedad, A., Moshou, D., Aerts, J. M., Van Hirtum, A., Ramon, H., & Berckmans, D.. (2001). AP—Animal Production Technology: Recognition System for Pig Cough based on Probabilistic Neural Networks. *Journal of agricultural engineering research*, 79(4), 449-457.
- Cortes, C., and Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Duhamel, P., & Vetterli, M. (1990). Fast Fourier transforms: a tutorial review and a state of the art. *Signal Processing*, 19(4), 259-299.
- Engel, S. J., Gilmartin, B. J., Bongort, K., and Hess, A. (2000). Prognostics, the real issues involved with predicting life remaining. *Aerospace Conference Proceedings*, 2000 IEEE, IEEE.

- Exadaktylos, V., Silva, M., Aerts, J. M., Taylor, C. J., and Berckmans, D. (2008). Real-time recognition of sick pig cough sounds. *Computers and electronics in agriculture*, 63(2), 207-214.
- Gasc, A., Sueur, J., Jiguet, F., Devictor, V., Grandcolas, P., Burrow, C., Depraetere, M., and Pavoine, S. (2013). Assessing biodiversity with sound: Do acoustic diversity indices reflect phylogenetic and functional diversities of bird communities?. *Ecological Indicators*, (25), 279-287.
- Gaston, K. J., and O'Neill, M. A. (2004). Automated species identification: why not? *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, (359), 655-667.
- Harma, A. (2003). Automatic identification of bird species based on sinusoidal modeling of syllables. *IEEE International Conference on Acoustics, Speech, and Signal Processing, 2003. Proceedings.(ICASSP'03)*, IEEE.
- Hu, Q., He, Z., Zhang, Z., & Zi, Y. (2007). Fault diagnosis of rotating machinery based on improved wavelet package transform and SVMs ensemble. *Mechanical Systems and Signal Processing*, 21(2), 688-705.
- Ishibuchi, H., Nakashima, T., and Murata, T. (1999). Performance evaluation of fuzzy classifier systems for multidimensional pattern classification problems. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 29(5), 601-618.
- Jarvis, A. M. and Robertson, A. (1999). Predicting population sizes and priority conservation areas for 10 endemic Namibian bird species. *Biological Conservation*, 88(1), 121-131.
- Kasten, E. P., McKinley, P. K. and Gage, S. H. (2010). Ensemble extraction for classification and detection of bird species. *Ecological Informatics*, 5(3), 153-166.
- Khazaei, M., Ahmadi, H. Omid, M. & Khazaei, M. (2012). Vibration condition monitoring of planetary gears based on decision level data fusion using Dempster-Shafer theory of evidence. *journal of vibroengineering*, 14(2), 838-851.
- Khazaei, M., Ahmadi, H. Omid, M. & Khazaei, M. (2014). Classifier fusion of vibration and acoustic signals for fault diagnosis and classification of planetary gears based on Dempster-Shafer evidence theory. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*. 228(1), 21-32.
- King, A. P. & West, M. J. (1977). Species identification in the North American cowbird: appropriate responses to abnormal song. *Science*, 195(4282), 1002-1004.
- Khazaei, M. (2012). Fault diagnosis & classification of their Characteristics for planetary gears using multi-sensory data fusion. MsC Thesis, University of Tehran. (In Farsi)
- Lee, C.-H., Lee, Y.-K., and Huang, R. Z. (2006). Automatic recognition of bird songs using cepstral coefficients. *Journal of Information Technology and Applications*, 1(1), 17-23.
- Lei, Y., He, Z., and Zi, Y. (2008). A new approach to intelligent fault diagnosis of rotating machinery. *Expert Systems with Applications*, 35, 1593-1600.
- Liao, Y. & Vemuri, V. R. (2002). Use of K-nearest neighbor classifier for intrusion detection. *Computers & Security*, 21(5), 439-448.
- McKay, C., Fujinaga, I., Depalle, P. (2005). jAudio: A feature extraction library. *Proceedings of the International Conference on Music Information Retrieval*.
- Miller, E. H. (1979). An approach to the analysis of graded vocalizations of birds. *Behavioral and Neural Biology*, 27(1), 25-38.
- Nowak, M. A., Wagoner, R. V., Begelman, M. C., and Lehr, D. E. (1997). The 67 Hz Feature in the Black Hole Candidate GRS 1915+ 105 as a Possible. *The Astrophysical Journal Letters*, 477(2), 1-5.
- Robertson, J., Harkin, C., and Govan, J. (1997) The Identification of Bird Feathers. Scheme for Feather Examination. *Journal of the Forensic Science Society*, 24: 85-98.
- Salahshoor, K., Kordestani, M., and Khoshro, M. S. (2010). Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. *Energy*, 35(12), 5472-5482.
- Yang, J., Yang, J.-y., Zhang, D., & Lu, J. F.. (2003). Feature fusion: parallel strategy vs. serial strategy. *Pattern Recognition*, 36(6), 1369-1381.