

تشخیص بیماری‌های نیوکاسل، برونشیت و آنفلوآنزای پرنده با استفاده از سیگنال صدای قلب و ماشین بردار

پشتیبان

محمد صادقی^۱، احمد بناکار^{۲*}، عبدالحمید شوشتری^۳

۱. دانشجوی کارشناسی ارشد، مهندسی مکانیک بیوسیستم، گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران

۲. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران

۳. استادیار، بخش بیماری‌های طیور، موسسه تحقیقات واکسن و سرم سازی رازی، کرج

(تاریخ دریافت: ۱۳۹۴/۱۰/۶ - تاریخ تصویب: ۱۳۹۵/۶/۲۷)

چکیده

در این پژوهش روشی هوشمند به منظور تشخیص توامان بیماری‌های نیوکاسل، آنفلوآنزا و RBF برونشیت پرنده از روی سیگنال صدای قلب پرداخته شده است. در ابتدا جوجه‌ها به ۴ دسته تقسیم شدند. یک گروه به عنوان نمونه‌های شاهد در نظر گرفته شدند و با ویروس هیچ‌گونه تماسی نداشتند و ۳ گروه باقی‌مانده به ترتیب به ویروس‌های نیوکاسل، آنفلوآنزا و برونشیت آلوده شدند. سیگنال‌های حوزه زمان صدای قلب توسط تبدیل فوری به سریع و تبدیل موجک گسسته دابچی نوع اول در دو سطح تجزیه به ترتیب به حوزه‌های فرکانس و زمان-فرکانس انتقال داده شدند. در مرحله داده‌کاوی از سیگنال‌های هر سه حوزه ۲۵ ویژگی آماری استخراج شدند و با استفاده از IDE بهترین ویژگی‌ها انتخاب شدند. با استفاده از ماشین بردار پشتیبان و نظریه شواهد دمپستر- شافر سیگنال‌های صدای قلب جوجه‌ها طبقه‌بندی شدند. دقت میانگین، Specificity و Sensitivity تلفیق طبقه‌بندها به منظور تشخیص بیماری‌ها به ترتیب ۸۱/۹۳، ۹۳/۲۹ و ۸۲/۲۸ درصد به دست آمد.

واژه‌های کلیدی: ماشین بردار پشتیبان، تبدیل موجک گسسته، بیماری طیور، نظریه شواهد دمپستر - شافر

مقدمه

از جمله برگشتن گردن می‌باشد و سویه ویسکروتراپیزم تمامی اندام‌های بدن از جمله سیستم تنفسی، سیستم گوارش، دستگاه قلب و سایر موارد را تحت تأثیر قرار می‌دهد (Nidzworski *et al.*, 2013). بیماری برونشیت عفونی (IBV^۴) از دیگر بیماری‌های رایج و شایع صنعت طیور می‌باشد. IBV جزو دسته کورونوویروس^۵ از خانواده کورونوویروس^۶ می‌باشد (Cook & Mockett, 1995; Malik *et al.*, 2004) این بیماری برای اولین بار در سال ۱۹۳۱ در ایالت متحده آمریکا گزارش شد (Schalk & Hawn, 1931). تشخیص IBV بسیار دشوار است و یافته‌های بالینی^۷ و آسیب شناختی^۸ نمی‌توانند به عنوان شاخص مرض^۹ به کار روند و این بیماری ممکن است با بیماری‌هایی نظیر آنفلوآنزا^{۱۰} و نیوکاسل اشتباه گرفته شود (Ganapathy, 2009). بیماری آنفلوآنزای طیور^{۱۱} یکی از بیماری‌های واگیردار تنفسی

امروزه بعضی از بیماری‌ها به دلیل خسارات اقتصادی که در فرآیند پرورش مرغ ایجاد می‌کنند از اهمیت ویژه‌ای برخوردارند. ویروس‌های آنفلوآنزا، نیوکاسل و برونشیت از بیماری‌های رایج طیور هستند که همه ساله خسارات اقتصادی فراوانی را به صنعت مرغداری تحمیل می‌نمایند.

بیماری نیوکاسل (NDV^۱) یک بیماری مسری بین پرندگان است که هم در گونه‌های اهلی و هم در گونه‌های وحشی شایع می‌باشد. این بیماری قابلیت سرایت به انسان را نیز داراست. این بیماری برای اولین بار در سال ۱۹۲۶ در نیوکاسل انگلستان شناسایی شد و از آن پس بدین نام مشهور گردید (Morgan, 1946). NDV دارای شاخه‌هایی با ژنوتیپ‌های مختلف است. شاخه ولوژنیک که حادثترین نوع بیماری می‌باشد و ۱۰۰٪ به مرگ پرنده می‌انجامد، به دو سویه عصبی^۲ و ویسکروتراپیزم^۳ منتهی می‌شود. سویه عصبی دارای علائم عصبی

4. Infectious Bronchitis Virus
5. coronavirus
6. coronaviridae
7. Clinics finding
8. Pathological findings
9. pathognomonic
10. Influenza
11. Avian Influenza

* نویسنده مسئول: ah_banakar@modares.ac.ir

1. Newcastle Disease Virus
2. Neurotropism
3. Viscerotropism

روش‌های مطمئنی در تشخیص و شناسایی بیماری حیوانات تبدیل شده‌اند (Acevedo et al., 2009, Gutierrez et al., 2010). شناسایی و استخراج اطلاعات مفید از یک سیگنال صوتی کار دشواری است و نیازمند روش‌های خاص می‌باشد. از این رو، تحقیقات گسترده‌ای در زمینه بیوسیستم به منظور شناسایی سیگنال بر اساس روش‌های هوشمند و داده‌کاوی و تلفیق داده‌ها صورت پذیرفته است.

(Chedad et al., 2001) طی پژوهشی با استفاده از شبکه عصبی مصنوعی به دسته‌بندی خوک‌ها از روی صدای سرفه‌ی آن‌ها پرداختند. در خلال این تحقیق لازم بود که صدای سرفه از سایر نویزهای موجود مانند صدای خرخر یا صدای فلز تمیز داده شود (Chedad 2001). (Acevedo et al., 2009) به تشخیص و طبقه‌بندی خودکار ۳ گونه پرنده و ۹ قورباغه با استفاده از ماشین بردار پشتیبان پرداختند. در این پژوهش صدای جانوران بر اساس متغیرهای مینیمم و ماکزیمم فرکانس، طول صدا و ماکزیمم توان تقسیم‌بندی و با استفاده از سه روش جدا کننده خطی، درخت تصمیم و ماشین بردار پشتیبان طبقه‌بندی شدند (Acevedo et al., 2009). (Gutierrez et al., 2010) بر اساس تجزیه و تحلیل سیگنال‌های صدا به تشخیص و طبقه‌بندی بیماری گراز همت گماردند. آنها مکانیزی طراحی کردند که تفاوت بین سیرکو ویروس نوع دوم^۵، سندروم تنفسی و یوفنمونیا میکوپلازما^۶ را تشخیص می‌داد. این بیماری‌ها با استفاده از نرم‌افزار متلب طبقه‌بندی شدند. در این راستا، سرفه حیوان با استفاده از یک میکروفن ضبط گردید و ویژگی‌های صدا از جمله توان، طول و گام صدا استخراج شدند. نتایج این تحقیق نشان داد که با استفاده از ویژگی‌های گام و شدت صدا می‌توان بیماری‌های مذکور را طبقه‌بندی کرد (Gutierrez et al., 2010). (Turkoglu et al., 2003) یک سیستم هوشمند بر اساس تشخیص الگو ارائه کردند که سیگنال داپلر ناشی از بیماری‌های دریچه قلب انسان را تفسیر می‌کرد. مدل ارائه شده متشکل از دو لایه موجک و پرسپترون چند لایه بود. لایه موجک به منظور استخراج ویژگی تطبیقی در حوزه زمان-فرکانس و پرسپترون چند لایه هم به منظور طبقه‌بندی مورد استفاده قرار گرفتند (Turkoglu et al., 2003). (Gupta et al., 2005) با استفاده از شبکه عصبی به تقسیم‌بندی صدای قلب انسان پرداختند. آن‌ها از ضرایب جزییات تبدیل موجک گسسته به عنوان ورودی شبکه عصبی بهره بردند. شبکه‌های عصبی به کار رفته عبارت بودند از

ویروسی طیور است که دارای قدرت انتشار سریع می‌باشد. امروزه ویروس‌های آنفلوانزا تحت تیپ H9N2 در گله‌های طیور اهلی سراسر دنیا در حال چرخش هستند (Guo et al., 1999 ; Naeem et al., 1999 ; Alexander, 2000 ; Guan et al., 2000 ; Guo et al., 2000). با وجود اینکه این تیپ آنفلوانزای طیور حدت زیادی ندارد اما این ویروس‌ها به پستانداران از جمله انسان نیز انتقال یافته‌اند (Lin et al., Guo et al., 1999 ; 2000). تیپ H9N2 ویروس آنفلوانزا برای اولین بار در سال ۱۹۶۶ در شمال آمریکا از بوقلمون جدا شد؛ در سال ۱۹۹۸ ویروس‌های H9N2 در هنگ‌کنگ از خوک‌های اهلی جدا شدند و یک سال بعد از دو کودک که علائم یک بیماری تبار تنفسی معمولی را نشان می‌دادند جدا گردیدند (Naeem et al., 1999 ; Peiris et al., 1999 Lin et al., 2000). پنج مورد دیگر گزارش ابتلاء انسان به آنفلوانزا ناشی از تحت تیپ H9N2 در جنوب چین وجود دارد (Guo et al., 1999). این ویروس در ایران نیز برای اولین بار در خرداد ماه ۱۳۷۷ (۱۹۹۸) توسط Vasfi Marandi و Bozorgmehri از یک واحد پرورش مرغ تخم‌گذار در استان تهران جدا شد (Vasfi Marandi & Bozorgmehri, 2002). از آن سال تا کنون این ویروس تلفات زیاد و خسارات سنگینی بر صنعت مرغ‌داری ایران وارد نموده است (Boroudjerdi et al., 2010).

از روش‌های مطمئن تشخیص بیماری‌های مذکور می‌توان به روش‌های مولکولی هم‌چون PCR، ELISA، RT-PCR نام برد (Corman et al., 2013, Haryanto et al., 2013 ; Nidzworski et al., 2013 Haryanto et al., 2015). اما این روش‌ها علاوه بر پرهزینه بودن، زمان‌بر نیز هستند. همچنین این روش‌ها به افراد خبیره و متخصص نیاز دارند. تحلیل سیگنال‌های صوتی حیوانات به عنوان یک آزمون غیرمخرب به منظور مطالعه وضعیت آن‌ها معرفی شده است. سیگنال صوتی پرندگان در واقع سیگنالی است که اطلاعات ارزشمندی از وضعیت پرنده به همراه دارد. از طریق این سیگنال‌ها می‌توان به اطلاعات مفیدی از جمله وضعیت سلامت، نوع گونه، اندازه جثه و غیره دست یافت (Kasten and McKinely, 2010). الگوریتم‌های یادگیری مانند جداکننده خطی^۱ (Simmonds et al., 1996)، درخت تصمیم^۲ (Parsons and Jones, 2000)، شبکه عصبی مصنوعی^۳ (Boddy et al., 1994) (Chesmore, 1998) و ماشین بردار پشتیبان^۴ (Fagerlund, 2007) به دلیل دقت بسیار بالا (> ۹۰٪ دقت) به

1. Linear Discriminant Analysis
2. Decision Tree
3. Artificial Neural Network (ANN)
4. Support Vector Machines (SVM)

5. circo virus type 2
6. mycoplasma hyopneumonia

ویروس‌های مذکور تایید شد. آزمون RT-PCR در این پژوهش بر اساس پروتوکول ۲ شرح داده شده توسط کاپوآ و الکساندر در کتاب مرجع بیماری‌های نیوکاسل-آنفلوانزا-برونشیت صورت پذیرفت (Capua & Alexander, 2009)). فرآیند ضبط سیگنال-های قلب، یک روز پس از تلقیح ویروس صورت پذیرفت. جوجه-های آلوده به ویروس نیوکاسل در روز سوم بعد از تلقیح ویروس از بین رفتند. سیگنال‌های قلب با استفاده از یک گوشی پزشکی مدل ۳۲۰۰ لیتمن (مدل ۳۲۰۰ با سه رنج فیلترینگ ۲۰-۲۰۰ هرتز، ۵۰۰-۱۰۰ هرتز و ۵۰۰-۵۰ هرتز و قطر دیافراگم ۵/۱ سانتی‌متر) ضبط شدند. این سیگنال‌ها به فرمت wav ذخیره و توسط نرم افزار MATLAB 2015a در سه حوزه زمان، فرکانس و زمان-فرکانس پردازش شدند. به علت نیرومند بودن ماشین بردار پشتیبان در حوزه مسائل پردازش سیگنال (Farfani et al., 2015)، از این طبقه‌بند به منظور تحلیل و طبقه‌بندی در این پژوهش استفاده شد و در مرحله تلفیق داده‌های چند حسگری، خروجی‌های SVM به عنوان ورودی‌های نظریه شواهد دمپستر - شافر در نظر گرفته شدند. شکل ۱ مراحل انجام گرفته در این پژوهش به منظور تشخیص توامان بیماری‌های نیوکاسل، برونشیت و آنفلوانزای پرند را بر اساس سیگنال صدای قلب و روش‌های هوش مصنوعی نشان می‌دهد.

پردازش سیگنال

با استفاده از یک پردازش سیگنال خوب و بررسی رفتار سیگنال می‌توان به استخراج اطلاعات مفید سیگنال و در نتیجه طبقه‌بندی آن‌ها پرداخت. یکی از اهداف پردازش سیگنال، فراهم کردن سیگنال مناسب برای مرحله داده‌کاوی است (Zhan & Wang et al., 2010; Makis, 2006). انتقال سیگنال از حوزه زمان به حوزه فرکانس یا زمان-فرکانس علاوه بر حذف نویز، می‌تواند در استخراج اطلاعات سودمندتر مثرتر باشد (Wang et al., 2010). در این پژوهش از سه روش پردازش سیگنال در حوزه زمان، فرکانس و زمان-فرکانس استفاده شده است.

سیگنال‌های حوزه زمان

سیگنال‌های این حوزه دارای اهمیت ویژه‌ای می‌باشند و تمامی پردازش‌های بعدی که بر روی صدا صورت می‌گیرد بر اساس سیگنال‌های حوزه زمان است. در واقع هر گونه آنالیز ثانویه و داده‌کاوی بر اساس سیگنال‌های این حوزه صورت می‌پذیرد.

سیگنال‌های حوزه فرکانس

از سیگنال‌های حوزه زمان نمی‌توان به ماهیت فرکانسی سیگنال پی برد؛ بنابراین به منظور دستیابی به ماهیت دوره‌ای یک سیگنال به پردازش آن در حوزه فرکانس نیاز است (Lee et al.,

شبکه‌های عصبی رشد و یادگیری (GAL^۱) و پرسپترون چند لایه با لایه پس‌خورد (MLP-BP). موجک استفاده شده در این پژوهش دابچی نوع دوم بود (Xu et al., 2005). (Gupta et al., 2012) طی پژوهشی ضمن تلفیق نتایج شبکه عصبی مصنوعی با روش دمپستر-شافر به عیب‌یابی دقیق یک توربین مبادرت ورزیدند. دقت به دست آمده در این پژوهش بسیار بالا و تقریباً معادل ۱۰۰٪ برآورد شد. این دقت توانمندی نظریه شواهد دمپستر-شافر^۲ و تلفیق طبقه‌بندها در کاربردهای عیب‌یابی را نشان می‌دهد (Xu et al., 2012). (Lee et al., 2015) با استفاده از ویژگی‌های صوت و ماشین بردار پشتیبان به تشخیص بیماری خوک پرداختند. در این پژوهش ۶۰ ویژگی آماری از جمله ماکزیم گام، PSD^۳، RMS^۴ و غیره به عنوان ویژگی‌های صدا استخراج شدند. به منظور کاهش فضای ویژگی و انتخاب بهترین ویژگی‌ها از روش AFSSA^۵ استفاده شد (Lee et al., 2015).

در پژوهش حاضر روشی مبتنی بر هوش مصنوعی و تلفیق داده چندحسگری به منظور تشخیص توامان بیماری‌های نیوکاسل، برونشیت و آنفلوانزا با استفاده از سیگنال صوتی قلب بررسی شده است تا مشکلات زمانی و اقتصادی دیگر روش‌های تشخیص بیماری برطرف شده و این روش در کنار سایر روش‌ها به مرغدار در امر تشخیص بیماری کمک شایانی بنماید.

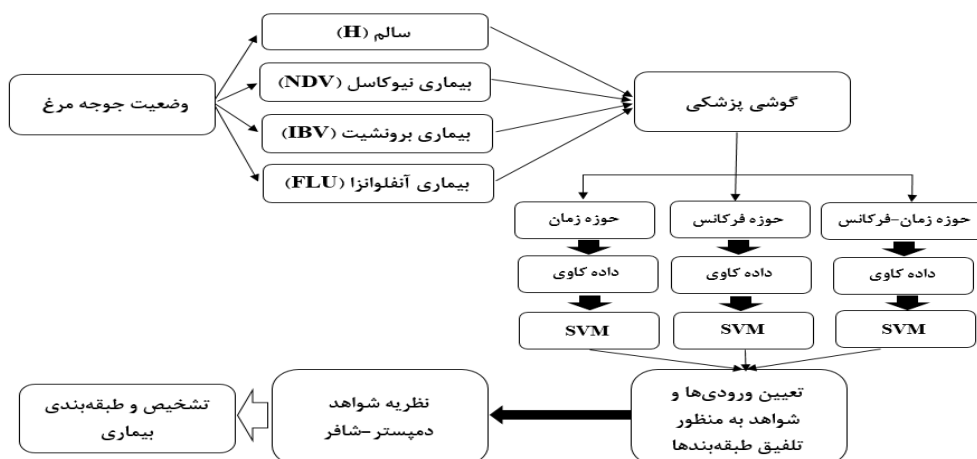
مواد و روش‌ها

این پژوهش در دانشکده کشاورزی دانشگاه تربیت مدرس تهران بر روی ۱۲۰ جوجه گوشتی نژاد راس^۶ انجام شد. جوجه-های ۱۴ روزه به ۴ دسته تقسیم شدند: دسته اول که تا پایان پژوهش با ویروس تماس نداشتند به عنوان نمونه‌های سالم شاهد در نظر گرفته شدند و دسته‌های دوم، سوم و چهارم به ترتیب به وسیله ویروس‌های نیوکاسل (سویه ویسکوتراپیزم)، برونشیت و آنفلوانزا (H9N2) آلوده شدند. نحوه تلقیح ویروس به صورت قطره چشمی بود. هر گروه در اتاقی جداگانه با شرایط محیطی یکسان نگهداری شدند (دما: ۲۸-۲۶ °C؛ رطوبت: ۶۰٪؛ پوشش کف هر قفس: خاک اره به ضخامت ۱۰ cm؛ تهویه اتاق: توسط فن‌های نصب شده بر روی دیوار). وجود ویروس نیوکاسل، برونشیت و آنفلوانزا با استفاده از روش RT-PCR و همچنین علائم کلینیکی در جوجه‌های تلقیح شده به

1. Grow and Learn
2. Dempster-Shafer Evidence Theory
3. Power Spectral Density
4. Root Mean Square
5. Acoustic Feature Subset Selection Algorithm
6. Ross

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

در این فرمول t و f به ترتیب زمان و فرکانس هستند و $x(f)$ تبدیل فوریه سیگنال زمانی $x(t)$ است.



شکل ۱. فرآیند هوش مصنوعی صورت پذیرفته به منظور تشخیص توامان بیماری‌های نیوکاسل، برونشیت و آنفلوانزا با استفاده از سیگنال‌های قلب پرنده.

نیازمند محاسبات پیچیده می‌باشد. برای نیل به قابلیت بارگذاری و کدگذاری تبدیل موجک بر روی رایانه از تبدیل موجک گسسته استفاده می‌شود. DWT توسط فرمول زیر تعریف می‌شود (Saravanan & Ramachandran, 2010):

$$DWT_{\psi}^x(j, k) = \Psi_{\psi}^x(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-2^j k}{2^j}\right) dt \quad (\text{رابطه ۲})$$

کمیت Ψ در رابطه ۲، تابعی است که دارای طول معین، میانگین صفر، رفتار نوسانی، کاملاً میرا و وظیفه پنجره بندی سیگنال را بر عهده دارد. در واقع کمیت Ψ که موجک مادر نام دارد، الگویی است جهت بازسازی سیگنال اولیه. با استفاده از تبدیل موجک گسسته، یک سیگنال به دو مولفه فرکانس پایین و فرکانس بالا تقسیم‌بندی می‌شود. در واقع رابطه ۲ به صورت دو فیلتر بالاگذر و پایین گذر، سیگنال را به تقریب‌ها و جزئیات تجزیه می‌نماید. در تبدیل موجک گسسته، تقریب معرف شکل اصلی سیگنال است و جزئیات بیانگر محدوده‌های فرکانس بالای نهفته در سیگنال اصلی هستند (Misiti et al., 1996). در این پژوهش به منظور پردازش سیگنال صدای قلب جوجه مرغ‌ها از DWT استفاده شد. منابع مختلفی کارا بودن DWT را در کاربردهای مختلف از جمله عیب‌یابی و پایش وضعیت بیان نموده‌اند (Gong et al., 1997). در این بین، پژوهش‌های متعددی موجک‌های خانواده دابچی^۲ را به منظور شناسایی

سیگنال‌های حوزه زمان-فرکانس

تبدیل موجک گسسته (DWT^1) یک تحلیل دوبعدی سیگنال به منظور رسیدن هم‌زمان به وضوح زمانی و فرکانسی می‌باشد و روشی بسیار موثر در پردازش سیگنال محسوب می‌گردد. در تبدیل موجک با تمامی مولفه‌های فرکانسی یک سیگنال مانند تبدیل فوریه سریع یکسان رفتار نمی‌شود بلکه هدف اصلی تبدیل موجک ارائه وضوح زمانی دقیق و فرکانسی نادقیق برای تغییرات تند و سریع؛ و وضوح فرکانسی دقیق و زمانی نادقیق برای تغییرات کند و آهسته است (Misiti et al., 1996). این مزیت مهم تبدیل موجک آن را برای کاربردهای پایش وضعیت بسیار مناسب ساخته است (Wu & Liu, 2009). تبدیل موجک در آنالیز سیگنال‌هایی که دارای نویز می‌باشند با توجه به ماهیت حذف ذاتی نویز دارای مزیت می‌باشد (Marchant, 2003). از دیگر مزیت‌های تبدیل موجک می‌توان به کاربرد گسترده آن در هموارسازی، فشرده‌سازی داده و تجزیه سیگنال‌های روی هم افتاده، اشاره نمود (Xia et al., Fu et al., 2005). در 2007 که تمامی این موارد به قابلیت تبدیل موجک در پایش پردازش سیگنال‌ها ختم می‌شود (Zhu et al., 2007). در پردازش سیگنال‌ها از دو نوع تبدیل موجک پیوسته و گسسته استفاده می‌شود. از آنجا که یک سیگنال پیوسته دارای بی‌نهایت مقدار است، وارد کردن آن‌ها به فرمول تبدیل موجک دشوار و

از ضرایب موجک ۲۵ ویژگی استخراج شد. ۲۵ ویژگی اول مربوط به ضریب تقریب تبدیل موجک، ۲۵ ویژگی دوم مربوط به ضریب جزییات مرحله اول و ۲۵ ویژگی سوم مربوط به ضریب جزییات مرحله دوم تبدیل موجک بودند.


انتخاب تعداد فراوان توابع ویژگی سبب عملکرد نامناسب طبقه‌بند می‌شود؛ در این شرایط طبقه‌بند نمی‌تواند بین دو گروه ویژگی استخراج شده از دو طبقه سیگنال، تمایزی قائل شود (Bagheri *et al.*, 2010). کیفیت ویژگی از آن جنبه حائز اهمیت است که ویژگی انتخاب شده بایستی برای شناسایی سیگنال مفید باشد. در این پژوهش از روش ارزیابی فاصله توسعه‌ای (IDE) به منظور انتخاب بهترین ویژگی‌ها استفاده شده است. در روش IDE ویژگی‌هایی که دارای دو شرط زیر باشند امتیازدهی می‌شوند (Lei *et al.*, 2008 & Bagheri *et al.*, 2010): ۱- ویژگی‌هایی که بیشترین اختلاف برون گروهی را داشته باشند. ۲- ویژگی‌هایی که کمترین اختلاف درون گروهی را داشته باشند.

هر یک از ویژگی‌ها که دو شرط مذکور را دارا باشد بیشترین امتیاز را دریافت می‌کند و نهایتاً با استفاده از حد آستانه دلخواه به انتخاب ویژگی پرداخته می‌شود.

طبقه‌بند: ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یک روش بسیار قدرتمند در طبقه‌بندی است که اولین بار توسط Cortes و Vapnik در سال ۱۹۹۵ میلادی بر پایه تئوری یادگیری آماری بنا نهاده شد (Cortes & Vapnik, 1995). SVM ابزاری بسیار مناسب به منظور حل مسائل یادگیری و شناسایی الگو می‌باشد. از کاربردهای ماشین بردار پشتیبان می‌توان به مسائل طبقه‌بندی، شناسایی تصویر، رده‌بندی متن، بیوانفورماتیک و غیره اشاره نمود. اگرچه SVM در ابتدا بر پایه طبقه‌بندی دو کلاس طراحی شده بود، اما اخیراً به منظور طبقه‌بندی مسائل چند کلاسه هم به کار رفته است. مطالعات بسیار زیادی در جهت توسعه SVM دو کلاسه به SVM چند کلاسه صورت پذیرفته است. معروف‌ترین روش‌های ماشین بردار پشتیبان چند کلاسه عبارتند از: "یکی در برابر یکی" (OAO^۱) و "یکی در برابر همه" (OAA^۲). یک مرور بسیار خوب از ماشین بردار پشتیبان و روابط آن در پژوهش (Hsu & Lin, 2002) صورت پذیرفته است. در پژوهش حاضر از روش OAO چند کلاسه با جدا کننده تابع پایه شعاعی گوسی (RBF^۳) استفاده شد.

سیگنال‌های قلب معرفی کرده‌اند و به کارا بودن آن اذعان داشته‌اند (Gokhale, 2012; Balachandran *et al.*, 2014). علاوه بر آن موجک مادر دابچی از لحاظ مورفولوژی بسیار شبیه به سیگنال‌های قلب هستند (Gokhale, 2012). بنابراین از موجک مادر دابچی به منظور پردازش سیگنال در حوزه زمان-فرکانس استفاده شد. تعداد سطوح موجک بر اساس سعی و خطا تعیین گردید (Gupta *et al.*, 2007; Banakar & Azeem, 2008). در این پژوهش با استفاده از موجک مادر دابچی نوع اول و تا ۲ مرحله به پردازش سیگنال‌های صدا پرداخته شد. شکل ۲ معرف یک تبدیل موجک گسسته تا ۲ مرحله است.



شکل ۲. تبدیل موجک گسسته پیاده سازی شده در ۲ مرحله

داده‌کاوی

استخراج و انتخاب ویژگی

ضرایب تبدیل موجک (یا خروجی هر سیگنال پردازنده دیگر) نمی‌توانند به صورت مسقیم 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. توابع ویژگی توابعی هستند که هر کدام به نوبه خود حالتی از یک سیگنال را بیان می‌کنند و حاوی اطلاعاتی هستند که به عنوان ورودی طبقه‌بند از آن‌ها می‌توان بهره جست. از این توابع می‌توان به ماکزیمم مقدار سیگنال، میانگین، کورتسیس و غیره اشاره نمود. این ویژگی‌ها بر روی سیگنال‌های پردازش شده در هر سه حوزه زمان، فرکانس (تبدیل فوریه سریع) و زمان-فرکانس (ضرایب تقریب و جزییات تبدیل موجک گسسته) تعریف می‌شوند و به منظور بررسی دقیق‌تر رفتار سیگنال‌های قلب مورد استفاده قرار می‌گیرند. ۲۵ ویژگی مورد استفاده در این پژوهش در جدول ۱ نشان داده شده است (Lei *et al.*, 2008 & Khazaei *et al.*, 2013). در این جدول $x(n)$ معرف سیگنال به ازای $n=1,2,\dots,N$ است که N تعداد نقاط داده‌ها می‌باشد.

از هر کدام از سیگنال‌های حوزه زمان و حوزه فرکانس به طور جداگانه ۲۵ ویژگی نامبرده در جدول ۱ استخراج گردید. همان‌گونه که در بخش ۲-۱-۳ نیز ذکر شد، از خانواده دابچی نوع ۱ به منظور پردازش در حوزه زمان-فرکانس استفاده شد. سیگنال‌ها به ضرایب تقریب و جزییات تجزیه شدند و از هر کدام

1. One Against One
2. One Against All
3. Radial Basic Function (RBF)

جدول ۱. فرمول ویژگی‌های استخراج شده از سیگنال قلب جوجه

| فرمول ویژگی‌ها | | |
|---|---|--|
| $T_1 = \frac{\sum_{n=1}^N x(n)}{N}$ | $T_{10} = \frac{T_2}{\frac{1}{N} \sum_{n=1}^N x(n) }$ | $T_{19} = \frac{1}{N} \sum_{n=1}^N (x(n) - T_2)^4$ |
| $T_2 = \max x(n) $ | $T_{11} = \frac{\sum_{n=1}^N (X(n) - T_1)^2}{N-1}$ | $T_{20} = \frac{1}{N} \sum_{n=1}^N (x(n) - T_2)^5$ |
| $T_3 = \sqrt{\frac{\sum_{n=1}^N (x(n) - T_1)^2}{N-1}}$ | $T_{12} = \frac{N}{\sum_{n=1}^N \frac{1}{x(n)}}$ | $T_{21} = \frac{1}{N} \sum_{n=1}^N (x(n) - T_2)^6$ |
| $T_4 = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$ | $T_{13} = \sqrt{\prod_{n=1}^N X(n)}$ | $T_{22} = \frac{T_{19}}{T_{11}^2}$ |
| $T_5 = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$ | $T_{14} = \frac{T_3}{T_2} \times 100$ | $T_{23} = \sum_{n=1}^N (x(n)^2)$ |
| $T_6 = \frac{T_{18}}{T_3^3}$ | $T_{15} = \sum_{n=1}^N \frac{(x(n) - T_1)}{N}$ | $T_{24} = \frac{3 \times (T_1 - x(\frac{N}{2}))}{T_3}$ |
| $T_7 = \frac{T_2}{T_5}$ | $T_{16} = \frac{\sum_{n=1}^N (x(n) - T_1)^3}{T_3^3}$ | $T_{25} = \frac{T_5}{T_1}$ |
| $T_8 = \frac{T_2}{\left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2}$ | $T_{17} = \frac{\sum_{n=1}^N (x(n) - T_1)^4}{(N-1)T_3^4}$ | |
| $T_9 = \frac{N \times \sqrt{\sum_{n=1}^N (x(n))^2}}{\sum_{n=1}^N x(n) }$ | $T_{18} = \frac{1}{N} \sum_{n=1}^N (x(n) - T_2)^3$ | |

دمپستر در سال ۱۹۶۷ بنا نهاده شد و شافر در سال ۱۹۷۶ به تکمیل این نظریه و رفع نواقص آن پرداخت و این نظریه را برای تحلیل اطلاعات غیرشفاف بسط داد (Al-Ani & Deriche, 2002). نظریه دمپستر- شافر بر پایه مقادیر اعتقادی تعدادی شاهد از یک سوژه و تلفیق انتخاب‌های این شواهد بنا شده است. در این نظریه نتایج تحلیل داده‌های طبقه‌بند به عنوان شواهد در نظر گرفته می‌شود و از خروجی‌های طبقه‌بند به عنوان ورودی‌های قوانین دمپستر- شافر استفاده می‌شود تا به بیشینه دقت طبقه‌بندی دسترسی یافت.

روابط حاکم بر نظریه شواهد دمپستر - شافر

با فرض آنکه مجموعه $\Omega = \{ \theta_1, \theta_2, \dots, \theta_k \}$ یک مجموعه شمارا از احتمالات برآورد شده از یک حالت باشند. این مجموعه چارچوب بررسی‌ها درباره وقوع یک اتفاق است و قدرت آن با 2^Ω

فرمول تابع شعاعی گوسی به صورت زیر می‌باشد (Burges, 1998):

$$K(x, y) = \exp\left(-\|x - y\|^2 / 2\sigma^2\right)$$

در این رابطه x و y به ترتیب به فضای ویژگی و فضای هدف اشاره دارند. در این رابطه هر چقدر مقدار سیگما (σ) بیشتر شود، پهنای ابر صفحه بیشتر شده و عمومی‌تر عمل می‌نماید و هر چقدر پهنای ابر صفحه کمتر شود به سمت محلی‌تر شدن سوق پیدا می‌کند.

دو پارامتر C و سیگما که به ترتیب فاکتور جریمه و پهنای ابر صفحه هستند، با سعی و خطا ۳۰ و ۲ در نظر گرفته شدند که دارای کمترین میزان خطا هستند.

نظریه شواهد دمپستر - شافر

نظریه شواهد ابتدا با انتشار نظریه حدود احتمالی بالا و پایین

$$\text{Bel}(A) \leq P(A) \leq PL(A) \xrightarrow{\text{If } PL(A)=\text{Bel}(A)} \text{PL}(A)=P(A)=\text{Bel}(A) \quad (\text{رابطه ۷})$$

قوانین نظریه شواهد دمپستر - شافر به منظور ترکیب طبقه-بندها

قوانین ترکیب رکن اساسی نظریه شواهد دمپستر- شافر را تشکیل می‌دهند. محاسبه‌ی توابع اعتماد و مقبولیت بر اساس ترکیب تابع جرم‌ها بدست می‌آیند. در این روش، ترکیب نظریات شواهد بر اساس عملگر AND صورت می‌پذیرد و مجموع احتمال یک پیشامد مانند A از ضرب احتمالات تمامی شواهد در وقوع پیشامدهایی که مساوی و یا شامل A باشند، محاسبه می‌گردد (Shafer, 2013). ترکیب دو تابع جرم دوتایی و همچنین تابع جرم چندتایی در معادلات ۸ و ۹ نشان داده شده است (Yager, 1987):

$$m_{12}(A) = m_1(B) \oplus m_2(C) = \frac{\sum_{B \cap C = A} m_1(B) \times m_2(C)}{1 - \sum_{B \cap C = \phi} m_1(B) \times m_2(C)}, \text{ when } A \neq \phi \quad (\text{رابطه ۸})$$

$$\begin{cases} m_1(A) \oplus m_2(A) \oplus \dots \oplus m_i(A) \\ = (1-K)^{-1} \times \sum_{\bigcap_{A_i=A}} m_i(A_i) \\ K = \sum_{\bigcap_{A_i=\phi}} m_i(A_i) \end{cases} \quad (\text{رابطه ۹})$$

فاکتور K تمامی مجموعه‌هایی که هیچ‌گونه اشتراکی ندارند را از تاثیرگذاری در نتایج برآوردها حذف می‌کند. از این رو فاکتور $NF = 1/1-k$ فاکتور نرمال کننده^۴ نامیده می‌شود (Sentz & Ferson, 2002).

نتایج

نتایج داده کاوی و انتخاب ویژگی

شکل‌های ۳ و ۴ یک نمونه از سیگنال از هر ۴ کلاس سالم، بیماری نیوکاسل، برونشیت و آنفلوآنزا را به صورت دو به دو نشان می‌دهند.

از هر کدام از سیگنال‌های حوزه زمان و حوزه فرکانس به طور جداگانه ۲۵ ویژگی نامبرده در جدول ۱ استخراج گردید. همان‌گونه که در بخش مواد و روش‌ها نیز ذکر گردید، از خانواده دابچی نوع ۱ به منظور پردازش در حوزه زمان-فرکانس استفاده گردید. سیگنال‌ها به ضرایب تقریب و جزئیات تجزیه شدند و از هر کدام از ضرایب موجک ۲۵ ویژگی استخراج شد.

تعریف می‌شود (Al-Ani & Deriche, 2002). سه تابع بسیار مهم در نظریه دمپستر - شافر وجود دارد که عبارتند از: تابع اساسی جرم احتمال (BPA^1)، تابع اعتماد (Bel^1) و تابع مقبولیت (PL^1) (Shafer, 1976).

تابع جرم با سه معادله زیر در نظر گرفته می‌شود (Shafer, 1976):

$$\begin{cases} m: P(X) \rightarrow [0, 1] \\ m(\phi) = 0 \\ \sum_{A \in P} m(A) = 1 \end{cases} \quad (\text{رابطه ۳})$$

$P(X)$ بیانگر قدرت شاهد X است و به منزله تمامی احتمالات برآورد شده از یک حالت می‌باشد. نماد Φ به مفهوم تابع تهی است و A حالتی از مجموعه قدرت می‌باشد $A \in P(X)$ (Klir & Wierman, 1999). مطابق روابط فوق، تابع جرم، نگاشت یک شاهد به وجود حالت A است، که با عددی بین صفر و یک تعریف می‌گردد. به شرطی که احتمال وقوع حالت Φ صفر باشد و نیز مجموع تابع جرم تمامی زیر مجموعه‌های مجموعه مرجع برابر با یک باشد. توابع اعتماد و مقبولیت به ترتیب حدود پایین و بالای یک حالت هستند که بر اساس BPA تعریف می‌شوند. میزان اعتماد به وقوع مجموعه A ($Bel(A)$) عبارتست از مجموع تابع جرم مجموعه B که $B \subseteq A$ در واقع تابع اعتماد بدینانه‌ترین برآورد از احتمال حالتی مثل A است. همچنین حد مقبولیت مجموعه A ($PL(A)$) از جمع تابع جرم مجموعه B که $B \cap A \neq \phi$ دست می‌آید (Klir & Wierman, 1999).

$Bel(A)$ و $PL(A)$ با دو معادله زیر نشان داده می‌شوند:

$$Bel(A) = \sum_{B|B \subseteq A} m(B) \quad (\text{رابطه ۴})$$

$$PL(A) = \sum_{B|B \cap A \neq \phi} P_h(B) = \sum_{B|B \cap A \neq \phi} m(B) \quad (\text{رابطه ۵})$$


با توجه به معادلات ۵ و ۶ واضح است که $Bel(A) \leq PL(A)$. از آنجا که اعتماد و مقبولیت A از تابع جرم آن محاسبه شده است می‌توان نوشت:

$$PL(A) = 1 - Bel(A) \quad (\text{رابطه ۶})$$


احتمال وقوع یک پیشامد A که با $P(A)$ نشان داده می‌شود، مقداری است مابین مقادیر مقبولیت و اعتماد آن پیشامد. بنابراین

1. Basic Propability Assigment function
2. Belief function
3. Plausibility function

پیداست، بین امتیاز ویژگی‌های F_{18} و F_{21} فاصله معناداری وجود دارد. به همین دلیل امتیاز حد آستانه $0/6$ برای انتخاب بهترین ویژگی‌های حوزه فرکانس انتخاب شد. با این تفاسیر ۶ ویژگی F_{13} ، F_{12} ، F_{20} ، F_4 ، F_{19} و F_{21} به ترتیب به عنوان بهترین ویژگی‌های سیگنال‌های حوزه فرکانس برای ورودی SVM برگزیده شدند.




شکل ۵. ویژگی‌های حوزه زمان و امتیاز آن‌ها.




شکل ۶. ویژگی‌های حوزه فرکانس و امتیاز آن‌ها.

امتیاز ویژگی‌های حوزه زمان-فرکانس در جدول ۲ نشان داده شده است. بر اساس این جدول و مشابه تحلیل‌های دو حوزه زمان و حوزه فرکانس، حد آستانه $0/6$ در نظر گرفته شد و ۷ ویژگی F_{21} ، F_{46} ، F_{19} ، F_{24} ، F_{73} و F_2 و F_{18} به ترتیب به عنوان بهترین ویژگی‌های سیگنال‌های حوزه زمان-فرکانس برای ورودی SVM برگزیده شدند. همان‌گونه که از ویژگی‌های انتخاب شده مشخص است، ویژگی‌های F_{18} و F_2 ، F_{24} ، F_{19} ، F_{21} و F_{73} به ترتیب مربوط به ضرایب جزئیات مرحله اول و دوم هستند. بنابراین مهم‌ترین اطلاعات سیگنال‌ها در ضرایب تقریب نهفته است.



شکل ۳. سیگنال‌های صدای قلب دو نمونه سالم (H) و آلوده به ویروس نیوکاسل (NDV)



شکل ۴. سیگنال‌های صدای قلب دو نمونه آلوده به ویروس برونشیت (IBV) و آلوده به ویروس آنفلوانزا (FLU)

۲۵ ویژگی اول مربوط به ضریب تقریب تبدیل موجک مرحله دوم، ۲۵ ویژگی دوم مربوط به ضریب جزئیات مرحله اول و ۲۵ ویژگی سوم مربوط به ضریب جزئیات مرحله دوم بودند. بر اساس روش IDE هر ویژگی امتیاز دهی شد و داده‌هایی که بیشترین امتیازها را داشتند به عنوان بهترین ویژگی‌ها انتخاب شدند تا از آن‌ها به عنوان ورودی‌های SVM استفاده شود.

شکل ۵ امتیاز ویژگی‌های استخراج شده از سیگنال‌های حوزه زمان را نشان می‌دهد. همانطور که از شکل ۵ پیداست، بین امتیاز ویژگی‌های F_2 و F_{11} فاصله معناداری وجود دارد. به همین دلیل برای

انتخاب بهترین ویژگی‌های حوزه زمان امتیاز حد آستانه $0/7$ در نظر گرفته شد. با این تفاسیر ۱۰ ویژگی F_8 ، F_{17} ، F_{22} ، F_{16} ، F_6 ، F_{21} ، F_{19} ، F_{18} و F_{20} و F_2 به ترتیب به عنوان بهترین ویژگی‌های سیگنال‌های حوزه زمان برای ورودی SVM برگزیده شدند.

شکل ۶ امتیاز ویژگی‌های استخراج شده از سیگنال‌های حوزه فرکانس را نشان می‌دهد. همان‌گونه که از شکل ۶

جدول ۲. ویژگی‌های حوزه زمان-فرکانس و امتیاز آن‌ها.

| امتیاز | ویژگی | امتیاز | ویژگی | امتیاز | ویژگی |
|--------|-------|--------|-------|--------|-------|
| ۰/۰۶ | ۶۸ | ۰/۲۳ | ۹ | ۱ | ۲۱ |
| ۰/۰۶ | ۱ | ۰/۲۳ | ۶۹ | ۰/۸۶ | ۴۶ |
| ۰/۰۴ | ۷۴ | ۰/۲۳ | ۸ | ۰/۸۵ | ۱۹ |
| ۰/۰۴ | ۵۸ | ۰/۲۱ | ۵۱ | ۰/۷۷ | ۲۴ |
| ۰/۰۴ | ۷۵ | ۰/۲۱ | ۲۳ | ۰/۷۵ | ۷۳ |
| ۰/۰۴ | ۶۴ | ۰/۲۰ | ۱۱ | ۰/۷۱ | ۲ |
| ۰/۰۴ | ۵۰ | ۰/۱۹ | ۴۸ | ۰/۶۹ | ۱۸ |
| ۰/۰۴ | ۳۹ | ۰/۱۸ | ۱۰ | ۰/۴۸ | ۵۲ |
| ۰/۰۳ | ۶۶ | ۰/۱۸ | ۱۵ | ۰/۴۸ | ۴۹ |
| ۰/۰۳ | ۵۶ | ۰/۱۸ | ۴۴ | ۰/۴۷ | ۶۲ |
| ۰/۰۳ | ۱۲ | ۰/۱۸ | ۱۴ | ۰/۴۶ | ۵۹ |
| ۰/۰۲ | ۶۷ | ۰/۱۷ | ۲۵ | ۰/۳۹ | ۳۶ |
| ۰/۰۲ | ۷۲ | ۰/۱۴ | ۴۳ | ۰/۳۶ | ۶۱ |
| ۰/۰۲ | ۷۰ | ۰/۱۲ | ۲۰ | ۰/۳۵ | ۲۷ |
| ۰/۰۱ | ۴۵ | ۰/۱۱ | ۴۲ | ۰/۳۵ | ۳۴ |
| ۰/۰۱ | ۶ | ۰/۱۱ | ۴۷ | ۰/۳۴ | ۱۳ |
| ۰/۰۱ | ۱۶ | ۰/۱۰ | ۳۷ | ۰/۳۲ | ۴ |
| ۰/۰۱ | ۶۳ | ۰/۰۹ | ۶۰ | ۰/۲۷ | ۲۶ |
| ۰/۰۰۸ | ۷ | ۰/۰۹ | ۳ | ۰/۲۶ | ۲۹ |
| ۰/۰۰۸ | ۳۲ | ۰/۰۸ | ۴۰ | ۰/۲۶ | ۵۵ |
| ۰/۰۰۷ | ۷۱ | ۰/۰۸ | ۵۴ | ۰/۲۶ | ۵۳ |
| ۰/۰۰۵ | ۵۷ | ۰/۰۸ | ۳۸ | ۰/۲۴ | ۱۷ |
| ۰/۰۰۳ | ۳۱ | ۰/۰۷ | ۳۳ | ۰/۲۴ | ۲۲ |
| ۰/۰۰۳ | ۴۱ | ۰/۰۶ | ۳۵ | ۰/۲۴ | ۳۰ |
| ۰/۰۰۱ | ۶۵ | ۰/۰۶ | ۵ | ۰/۲۴ | ۲۸ |

عملکرد ماشین بردار پشتیبان (SVM)

ویژگی‌های انتخاب شده در مرحله انتخاب ویژگی به عنوان ورودی SVM مورد استفاده قرار گرفتند. داده‌های پژوهش شامل ۹۰ سیگنال صدای قلب جوجه مرغ سالم، ۹۰ سیگنال صدای قلب جوجه مرغ آلوده به ویروس نیوکاسل، ۹۰ سیگنال صدای قلب جوجه مرغ آلوده به ویروس برونشیت و ۹۰ سیگنال صدای قلب جوجه مرغ آلوده به ویروس آنفلوآنزا بود (در مجموع ۳۶۰ نمونه سیگنال صدای قلب) که ۷۰٪ نمونه‌ها (۲۵۲ نمونه سیگنال صدای قلب) به صورت تصادفی برای آموزش SVM انتخاب شد. ۳۰ درصد باقی‌مانده (۱۰۸ نمونه سیگنال صدای قلب) به منظور آزمون ماشین بردار پشتیبان به کار گرفته شد تا دقت سامانه طراحی شده به منظور تشخیص بیماری نیوکاسل، آنفلوآنزا و برونشیت بدست آید. دقت آموزش طبقه‌بند در سه حوزه زمان، فرکانس و زمان-فرکانس به ترتیب ۶۰، ۴۴ و ۷۴ درصد به دست آمد. به منظور بررسی عملکرد طبقه‌بند و نظریه شواهد دمپستر- شافر از سه پارامتر مهم دقت کلی طبقه‌بندی،

تشخیص (Specificity) و حساسیت (Sensitivity) استفاده شده است. دو پارامتر تشخیص و حساسیت به صورت زیر تعریف می‌شوند:

Sensitivity (حساسیت): توانایی طبقه‌بند به منظور تشخیص صحیح هر بیماری.

Specificity (تشخیص): توانایی طبقه‌بند به منظور رد کردن دیگر بیماری‌ها و اشتباه گرفته نشدن با دیگر بیماری‌ها.

دقت کلی طبقه‌بند در زیر آورده شده و همچنین نحوه محاسبه Sensitivity و Specificity برای کلاس نیوکاسل (NDV) بر اساس جدول ۳ در زیر بیان گردیده است:

$$Sensitivity\ y = \frac{S(2,2)}{S(2,1) + S(2,2) + S(2,3) + S(2,4)}$$

$$Specificity\ y = \left[\frac{S(1,1)}{S(1,1) + S(1,2)} + \frac{S(3,3)}{S(3,3) + S(3,2)} + \frac{S(4,4)}{S(4,4) + S(4,2)} \right]^{1/3}$$

$$دقت\ کلی\ طبقه\ بند = \frac{S(1,1) + S(2,2) + S(3,3) + S(4,4)}{S(1,1) + S(1,2) + \dots + S(4,4)}$$

جدول ۳. ماتریس اغتشاش طبقه‌بند به ازای هر ۴ کلاس سالم (H)، نیوکاسل (NDV)، برونشیت (IBV) و آنفلوانزا (FLU)

| وضعیت | سالم | نیوکاسل | برونشیت | آنفلوانزا |
|-----------|--------|---------|---------|-----------|
| سالم | S(۱و۱) | S(۱و۲) | S(۱و۳) | S(۱و۴) |
| نیوکاسل | S(۲و۱) | S(۲و۲) | S(۲و۳) | S(۲و۴) |
| برونشیت | S(۳و۱) | S(۳و۲) | S(۳و۳) | S(۳و۴) |
| آنفلوانزا | S(۴و۱) | S(۴و۲) | S(۴و۳) | S(۴و۴) |

نمود. همچنین عملکرد طبقه‌بند در حوزه فرکانس با کمترین دقت همراه بود. همان‌گونه که از جدول ۶ مشخص است، Specificity طبقه‌بند که به منزله توانایی آن برای رد کردن دیگر کلاس‌هاست ۸۳/۰۸٪ بدست آمد و Sensitivity طبقه‌بند با توانایی ۶۲/۰۳٪ برآورد شد. پس از آنجا که دقت حوزه فرکانس بسیار پایین بود، در مرحله تلفیق داده‌ها در سطح تصمیم، دو حوزه زمان و زمان-فرکانس با یکدیگر تلفیق شدند تا از اطلاعات آن‌ها در سطح تصمیم استفاده شود و بهترین عملکرد طبقه‌بندی بدست آید.

جداول ۴، ۵ و ۶ به ترتیب عملکرد ماشین بردار پشتیبان برای هر سه حوزه زمان، فرکانس و زمان-فرکانس را در روز دوم بیماری نشان می‌دهند.

با توجه به جداول ۴ تا ۶ بیشینه دقت طبقه‌بندی در حالت استفاده از سیگنال‌های حوزه زمان-فرکانس ۶۲/۰۳٪ به دست آمد. اعداد ماتریس اغتشاش بدین صورت هستند که به عنوان مثال در ردیف نیوکاسل جدول ۶، طبقه‌بند از ۲۷ نمونه نیوکاسل، ۲۹ نمونه را به درستی نیوکاسل تشخیص داد و ۴، ۳ و ۱ نمونه را به اشتباه سالم، برونشیت و آنفلوانزا طبقه‌بندی

جدول ۴. عملکرد ماشین بردار پشتیبان در حوزه زمان.

| | | عملکرد طبقه‌بند | | | | | | |
|--------------|-----------|-----------------|---------|---------|-----------|------------------------|-------------------------|--------------------------|
| | | سالم | نیوکاسل | برونشیت | آنفلوانزا | تشخیص ^۱ (%) | حساسیت ^۲ (%) | دقت میانگین طبقه‌بند (%) |
| حالت چوبه | سالم | ۱۴ | ۵ | ۴ | ۴ | ٪ ۸۶/۳۱ | ٪ ۵۱/۸۵ | ٪ ۵۴/۶۲ |
| | نیوکاسل | ۲ | ۱۷ | ۶ | ۲ | ٪ ۶۹/۱۰ | ٪ ۶۲/۹۶ | |
| | برونشیت | ۲ | ۸ | ۱۵ | ۲ | ٪ ۷۴/۶۳ | ٪ ۵۵/۵۵ | |
| | آنفلوانزا | ۳ | ۶ | ۵ | ۱۳ | ٪ ۸۵/۱۶ | ٪ ۴۸/۱۴ | |

جدول ۵. عملکرد ماشین بردار پشتیبان در حوزه فرکانس.

| | | عملکرد طبقه‌بند | | | | | | |
|--------------|-----------|-----------------|---------|---------|-----------|-----------|------------|--------------------------|
| | | سالم | نیوکاسل | برونشیت | آنفلوانزا | تشخیص (%) | حساسیت (%) | دقت میانگین طبقه‌بند (%) |
| حالت چوبه | سالم | ۹ | ۷ | ۷ | ۴ | ٪ ۵۵/۲۷ | ٪ ۳۲/۳۳ | ٪ ۳۱/۴۸ |
| | نیوکاسل | ۶ | ۱۰ | ۶ | ۵ | ٪ ۵۰/۹۷ | ٪ ۳۷/۰۳ | |
| | برونشیت | ۷ | ۸ | ۷ | ۵ | ٪ ۶۱/۸۰ | ٪ ۲۵/۹۲ | |
| | آنفلوانزا | ۷ | ۸ | ۴ | ۸ | ٪ ۶۴/۷۴ | ٪ ۲۹/۶۲ | |

جدول ۶. عملکرد ماشین بردار پشتیبان در حوزه زمان-فرکانس.

| | | عملکرد طبقه‌بند | | | | | | |
|--------------|-----------|-----------------|---------|---------|-----------|-----------|------------|--------------------------|
| | | سالم | نیوکاسل | برونشیت | آنفلوانزا | تشخیص (%) | حساسیت (%) | دقت میانگین طبقه‌بند (%) |
| حالت چوبه | سالم | ۱۹ | ۶ | ۱ | ۱ | ٪ ۸۵/۶۸ | ٪ ۷۰/۳۷ | ٪ ۶۲/۰۳ |
| | نیوکاسل | ۴ | ۱۹ | ۳ | ۱ | ٪ ۷۳/۵۰ | ٪ ۷۰/۳۷ | |
| | برونشیت | ۱ | ۶ | ۱۷ | ۳ | ٪ ۸۱/۵۰ | ٪ ۶۲/۹۶ | |
| | آنفلوانزا | ۳ | ۵ | ۷ | ۱۲ | ٪ ۹۱/۶۶ | ٪ ۴۴/۴۴ | |

1. Specificity

2. Sensitivity

تلفیق شواهد در نظریه دمپستر-شافر

جدول ۷، شواهد نظریه دمپستر - شافر را نشان می‌دهد. بدین منظور، خروجی SVM به ازای داده‌های حوزه زمان به عنوان شاهد اول و خروجی SVM به ازای داده‌های حوزه زمان-فرکانس به عنوان شاهد دوم نظریه دمپستر- شافر در نظر گرفته شدند.

به عنوان مثال، دقت تشخیص بیماری نیوکاسل (NDV) بر اساس تلفیق طبقه‌بندهای حوزه زمان و زمان-فرکانس در جدول ۸ نشان داده شده است. این جدول، ضرب ماتریسی برآورد شواهد E1 و E2 از وقوع این نوع بیماری را نشان می‌دهد. این ضرب ماتریسی، برآورد عطفی اشتراک بین دو شاهد در میزان برآورد احتمال وجود بیماری نیوکاسل در جوجه است.

جدول ۷. شواهد نظریه دمپستر-شافر.

| شاهد | E1 : شاهد اول (حوزه زمان) | | | | E2 : شاهد دوم (حوزه زمان - فرکانس) | | | |
|-----------|---------------------------|---------|---------|-----------|------------------------------------|---------|---------|-----------|
| | سالم | نیوکاسل | برونشیت | آنفلوآنزا | سالم | نیوکاسل | برونشیت | آنفلوآنزا |
| وضعیت | سالم | نیوکاسل | برونشیت | آنفلوآنزا | سالم | نیوکاسل | برونشیت | آنفلوآنزا |
| سالم | ٪ ۵۱/۸۵ | ٪ ۱۸/۵۱ | ٪ ۱۴/۸۱ | ٪ ۱۴/۸۱ | ٪ ۷۰/۳۷ | ٪ ۲۲/۲۲ | ٪ ۳/۷۰ | ٪ ۳/۷۰ |
| نیوکاسل | ٪ ۷/۴۰ | ٪ ۶۲/۹۶ | ٪ ۲۲/۲۲ | ٪ ۷/۴۰ | ٪ ۱۴/۸۱ | ٪ ۷۰/۳۷ | ٪ ۱۱/۱۱ | ٪ ۳/۷۰ |
| برونشیت | ٪ ۷/۴۰ | ٪ ۲۹/۶۲ | ٪ ۵۵/۵۵ | ٪ ۷/۴۰ | ٪ ۳/۷۰ | ٪ ۲۲/۲۲ | ٪ ۶۲/۹۶ | ٪ ۱۱/۱۱ |
| آنفلوآنزا | ٪ ۱۱/۱۱ | ٪ ۲۲/۲۲ | ٪ ۱۸/۵۱ | ٪ ۴۸/۱۴ | ٪ ۱۱/۱۱ | ٪ ۱۸/۵۱ | ٪ ۲۵/۹۲ | ٪ ۴۴/۴۴ |

جدول ۸. برآورد عطفی اشتراک شواهد اول و دوم در تشخیص بیماری نیوکاسل

| تلفیق شواهد اول و دوم در تشخیص بیماری نیوکاسل | E1 : طبقه‌بند حوزه زمان | | | | | |
|---|-------------------------|---------|------------------------|-----------|-------|-------|
| | سالم | نیوکاسل | برونشیت | آنفلوآنزا | | |
| | ۰/۰۷۴ | ۰/۶۲۹ | ۰/۲۲۲ | ۰/۰۷۴ | | |
| E2 : طبقه‌بند حوزه زمان - فرکانس | سالم | ۰/۱۴۸ | ۰/۰۷۴ × ۰/۱۴۸ = ۰/۰۱۰۹ | ۰/۰۹۳ | ۰/۰۳۲ | ۰/۰۰۲ |
| | نیوکاسل | ۰/۷۰۳ | ۰/۰۵۲ | ۰/۴۴۲ | ۰/۱۵۶ | ۰/۰۱۶ |
| | برونشیت | ۰/۱۱۱ | ۰/۰۰۸ | ۰/۰۶۹ | ۰/۰۲۴ | ۰/۰۴۶ |
| | آنفلوآنزا | ۰/۰۳۷ | ۰/۰۰۲ | ۰/۰۲۳ | ۰/۰۰۸ | ۰/۰۰۸ |

۹۱٪ افزایش یافته است. همچنین میزان تشخیص اشتباه کلاس‌های دیگر نیز به شدت کاهش پیدا کرده است. جدول ۱۰ دقت طبقه‌بندی بیماری‌ها را بر اساس تلفیق طبقه‌بندهای حوزه زمان و زمان-فرکانس نشان می‌دهد (E1 و E2). با توجه به جدول ۱۰ مشاهده می‌شود که با تلفیق شواهد حوزه زمان و زمان-فرکانس دقت طبقه بندی به ۸۱/۹۳ درصد افزایش یافته است. همچنین دو فاکتور مهم Sensitivity و Specificity به بالای ۹۰ درصد رسیدند. بر اساس این جدول کمترین دقت تشخیص مربوط به بیماری آنفلوآنزا بود.

در جدول ۸، تمامی حالت‌هایی که شواهد در آن‌ها دارای تضاد هستند و اشتراکی در تشخیص حالت هدف ندارند با نماد ϕ نشان داده شده است و ϕ (۱و۲) یعنی شاهد اول حالت دوم (NDV) و شاهد دوم حالت اول (H) را تشخیص داده‌اند. جدول ۹ جزییات محاسبات تلفیق طبقه‌بندهای حوزه زمان و حوزه زمان-فرکانس را به منظور تشخیص بیماری نیوکاسل نشان می‌دهد. با توجه به جداول ۷ و ۹ مشاهده می‌شود که با استفاده از روش دمپستر- شافر و تلفیق طبقه‌بندهای دو حوزه زمان و فرکانس دقت تشخیص بیماری نیوکاسل از کمتر از ۷۰٪ به

جدول ۹. محاسبات تلفیق دو طبقه‌بند در حوزه زمان و حوزه فرکانس به منظور تشخیص بیماری نیوکاسل

| دقت تلفیقی (%) | شاخص نرمال سازی | ترکیب عطفی شواهد | وضعیت جوجه |
|----------------|--|------------------|------------|
| ۲/۲۶% | $K = \sum \phi(i, j) = 0/512$ | ۰/۱۰۹ | سالم |
| ۹۱/۶۴% × ۱۰۰ = | | ۰/۴۴۲ | نیوکاسل |
| ۲/۰۷۲% × ۱۰۰ = | $\rightarrow NF = \frac{1}{1-K} = 2/072$ | ۰/۰۲۴ | برونشیت |
| ۵/۱۰% | | ۰/۰۰۸ | آنفلوانزا |

جدول ۱۰. نتایج تلفیق شواهد حوزه زمان و زمان-فرکانس ($E1 \oplus E2$)

| عملکرد نظریه شواهد دمپستر- شافر | | | | | | | | |
|---------------------------------|------------|-----------|-----------|---------|---------|-------|-----------|--------|
| دقت میانگین طبقه‌بندی (%) | حساسیت (%) | تشخیص (%) | آنفلوانزا | برونشیت | نیوکاسل | سالم | | |
| | | | | | | | | ۸۱/۹۳% |
| | | ۸۵/۹۴% | ۰/۵۶% | ۵/۱% | ۹۱/۶۴% | ۲/۲۶% | نیوکاسل | سالم |
| | | ۹۱/۵۷% | ۱/۹۱% | ۸۱/۶۱% | ۱۵/۳۶% | ۰/۶۴% | برونشیت | سالم |
| | | ۹۸/۵۴% | ۶۷/۳۹% | ۱۵/۱۲% | ۱۲/۹۶% | ۳/۸۸% | آنفلوانزا | سالم |

بحث

با توجه به جداول ۴ تا ۶ بیشینه دقت طبقه‌بند به ازای سیگنال‌های حوزه زمان-فرکانس به دست آمد. سایر محققین نیز به برتری تبدیل موجک در مقایسه با دیگر روش‌های پردازش سیگنال اذعان داشته‌اند (Ionescu & Llobet, 2002). Akin (2002) عملکرد تبدیل موجک و تبدیل فوریه سریع را به منظور تشخیص سیگنال‌های EEG بررسی کردند و به این نتیجه رسیدند که تبدیل موجک بهتر از تبدیل فوریه سریع عمل می‌کند (Akin, 2002). همان‌گونه که در جدول ۵ نشان داده شده است، کمترین دقت طبقه‌بندی به ازای سیگنال‌های حوزه فرکانس بدست آمد. علت این امر این است که ضربان قلب دارای فرکانس‌های غالبی است که در یک لحظه بسیار کوتاه رخ می‌دهند، اما در طول سیگنال، مقادیر فرکانس غالب وجود ندارد. در این شرایط تبدیل فوریه قادر به تشخیص فرکانس غالب کوتاه مدت نمی‌باشد (Iyer et al., 2012). با توجه به جداول ۶ و ۱۰ دقت طبقه‌بندی با استفاده از روش تلفیق داده‌ها از ۶۲ درصد به ۸۱ درصد افزایش یافته است. با استفاده از نظریه شواهد دمپستر - شافر دقت به صورت میانگین به ۱۹ درصد افزایش یافته است. این مهم نشان از قدرتمندی و مفید بودن استفاده از راهبرد تلفیق داده‌ها در افزایش دقت تشخیص بیماری است. این نتایج توسط پژوهش‌های مشابه نیز مورد تاکید قرار گرفته است (Ruhm, 2007; Zhu, 2002). بر اساس جدول ۱۰، دقت طبقه‌بندی، Specificity و Sensitivity نظریه شواهد دمپستر - شافر به ترتیب ۸۱/۹۳، ۹۳/۲۹ و ۸۲/۲۸ درصد بدست آمد. بنابراین تشخیص توامان بیماری‌های

نیوکاسل، آنفلوانزا و برونشیت بر اساس سیگنال‌های صوتی قلب با موفقیت همراه بوده است. دیگر محققین نیز به تشخیص بیماری حیوانات بر اساس سیگنال‌های زیستی اذعان داشته‌اند. (Chedad et al., 2001) طی پژوهشی با استفاده از شبکه عصبی مصنوعی به دسته‌بندی خوک‌ها از روی صدای سرفه آن‌ها پرداختند. در این پژوهش دقت طبقه‌بندی ۹۱/۹ درصد گزارش شده است (Chedad 2001). در پژوهشی دیگر، Lee et al. (2015) با استفاده از ویژگی‌های صوت و ماشین بردار پشتیبان به تشخیص بیماری خوک پرداختند که الگوریتم آن‌ها توانست با دقت ۹۸/۴ درصد به تشخیص و طبقه‌بندی بیماری بپردازد (Lee et al., 2015). همان‌گونه که در بررسی پژوهش‌ها آشکار است، محققین فقط به تشخیص نمونه‌های سالم و بیمار پرداخته‌اند و در پژوهششان یک بیماری خاص را تشخیص داده‌اند. اما مزیت پژوهش حاضر بر این است که سه نوع بیماری به صورت همزمان تشخیص داده شده‌اند و عملکرد تلفیق طبقه‌بندیها منحصر به جداسازی جوجه سالم و بیمار نیست بلکه قادر است بیماری‌های مذکور را تشخیص دهد و در مرحله بعد طبقه‌بندی نماید.

نتیجه‌گیری

در این پژوهش سامانه‌ای هوشمند به منظور تشخیص بیماری‌های نیوکاسل، آنفلوانزا و برونشیت مرغ بر اساس تجزیه و تحلیل سیگنال صدای قلب جوجه مرغ طراحی گردید. دقت طبقه‌بندی، Specificity و Sensitivity نظریه شواهد دمپستر-شافر به منظور تشخیص بیماری طیور بر اساس سیگنال‌های صدای قلب

سیگنال صوتی قلب موفق عمل نموده‌اند. نتایج همچنین بیان می‌دارند که با استفاده از سامانه طراحی شده می‌توان به تشخیص بیماری طیور بر اساس سیگنال صدای قلب آن‌ها پرداخت و روش مذکور این پژوهش می‌تواند در کنار دیگر روش‌های تشخیص بیماری طیور ایفای نقش کند. از مزیت‌های روش تشخیص هوشمند معرفی شده در این پژوهش می‌توان به کم هزینه بودن و تشخیص به موقع بیماری اشاره نمود. نتایج این پژوهش نشان از مفید و موثر بودن روش‌های هوشمند در تشخیص بیماری پرندگان با استفاده از سیگنال صدای قلب آن‌ها دارند.

REFERENCES

- Acevedo, M. A., Corrada-Bravo, C. J., Corrada-Bravo, H., Villanueva-Rivera, L. J. & Aide, T. M. (2009). Automated classification of bird and amphibian calls using machine learning: A comparison of methods. *Ecological Informatics*, 4(4): 206-214.
- Akin, M. (2002). Comparison of wavelet transform and FFT methods in the analysis of EEG signals. *Journal of medical systems*, 26(3), 241-247.
- Al-Ani, A. & Deriche, M. (2002). A new technique for combining multiple classifiers using the Dempster-Shafer theory of evidence. *Journal of Artificial Intelligence Research*: 333-361.
- Alexander, D. J. (2000). A review of avian influenza in different bird species. *Veterinary microbiology*, 74(1), 3-13.
- Balachandran, A., Ganesan, M. & Sumesh, E. (2014). Daubechies algorithm for highly accurate ECG feature extraction. *Green Computing Communication and Electrical Engineering (ICGCCEE)*, 2014 International Conference on, IEEE.
- Banakar, A. & Azeem, M. F. (2008). Artificial wavelet neuro-fuzzy model based on parallel wavelet network and neural network. *Soft Computing*, 12(8): 789-808.
- Bagheri, B., Ahmadi, H., Labbafi, R. (2010). Application of data mining and feature extraction on intelligent fault diagnosis by artificial neural network and k-nearest neighbor, in: XIX International Conference on Electrical Machines - ICEM, Rome, IEEE, pp. 1-7.
- Boddy, L., Morris, C.W., Wilkins, M.F., Tarran, G.A. & Burkill, P.H. (1994). Neural network analysis of flow cytometric data for 40 marine phytoplankton species. *Cytometry*, 15:283-293.
- Boroudjerdi, F., Mardjanmehr, S., Shushtari, A., Tavassoli, A., Mirsalimi, S. & Bahmaninejad, M. (2010). An experimental study on histopathological lesions of Iranian isolates of influenza A (H9N2) virus in BALB/C mouse. *Journal of Veterinary Research*, 65(3): 231-238, 267.
- Burges, C. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2): 121-167.
- Capua, I. & Alexander, D. J. (2009). Avian influenza and Newcastle disease: a field and laboratory manual, Springer Science & Business Media.
- Chedad, A., Moshou, D., Aerts, J., Van Hirtum, A., Ramon, H. & Berckmans, D. (2001). Recognition System for Pig Cough based on Probabilistic Neural Networks. *J. agric. Engng Res*, 79, 449-457.
- Chesmore, E. D., Femminella, O.P. & Swarbrick, M.D. (1998). Automated analysis of insect sounds using time-encoded signals and expert systems - a new method for species identification. *Information Technology, Plant Pathology and Biodiversity*. CAB International, Wallingford, 273-287.
- Cook, J. K. & Mockett, A. (1995). Epidemiology of infectious bronchitis virus. *The coronaviridae*, Springer, 317-335.
- Corman, V., Eickmann, M., Landt, O., Bleicker, T., Brunink, S., Eschbach-Bludau, M., Matrosovich, M., Becker, S. & Drosten, C. (2013). Specific detection by real-time reverse-transcription PCR assays of a novel avian influenza A (H7N9) strain associated with human spillover infections in China. *Euro Surveill*, 18(16): 20461.
- Cortes, C. & 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.
- Fagerlund, S. (2007). Bird species recognition using support vector machines. *EURASIP Journal of Advances in Signal Processing*, 1-8.
- Farfani, H., Behnamfar, F. & Fathollahi, A. (2015). Dynamic analysis of soil-structure interaction using the neural networks and the support vector machines, *Expert Systems with Applications*, 42 (22): 8971-8981.
- Fu, X., Yan, G., Chen, B. & Li, H. (2005). Application of wavelet transforms to improve prediction precision of near infrared spectra. *Journal of Food Engineering*, 69(4): 461-466.
- Ganapathy, K. (2009). Diagnosis of infectious bronchitis in chickens. *In Practice*, 31(9): 424-431.
- در روز دوم بعد از تلقیح ویروس به ترتیب ۸۱/۹۳، ۹۳/۲۹ و ۸۲/۲۸ درصد محاسبه شد. در بین بیماری‌های بررسی شده کمترین و بیشترین دقت تشخیص به ترتیب مربوط به بیماری‌های آنفلوانزا (۶۷/۳۹ درصد) و نیوکاسل (۹۱/۶۴ درصد) بود. بنابراین می‌توان گفت که دقت تشخیص روش پیشنهادی در خصوص شناسایی بیماری نیوکاسل بسیار کارسازتر از سایر بیماری‌هاست. از آنجا که شناسایی هرچه سریع‌تر بیماری در کاهش تلفات و یا جلوگیری از انتشار آن اهمیت دارد، نتایج حاصل از این پژوهش نشان می‌دهند که روش‌های هوشمند در تشخیص بیماری‌های نیوکاسل، برونشیت و آنفلوانزا از روی

- Gokhale, P. S. (2012). ECG Signal De-noising using Discrete Wavelet Transform for removal of 50Hz PLI noise. *International Journal of Emerging Technology and Advanced Engineering*, 2(5): 81-85.
- Gong, W., Obikawa, T. & Shirakashi, T. (1997). Monitoring of tool wear states in turning based on wavelet analysis. *JSME international journal. Series C, dynamics, control, robotics, design and manufacturing*, 40(3): 447-453.
- Guan, Y., Shortridge, K., Krauss, S., Chin, P., Dyrting, K., Ellis, T., Webster, R. & Peiris, M. (2000). H9N2 influenza viruses possessing H5N1-like internal genomes continue to circulate in poultry in southeastern China. *Journal of virology*, 74(20): 9372-9380.
- Guo, Y., Krauss, S., Senne, D., Mo, I., Lo, K., Xiong, X., Norwood, M., Shortridge, K., Webster, R. & Guan, Y. (2000). Characterization of the pathogenicity of members of the newly established H9N2 influenza virus lineages in Asia. *Virology*, 267(2): 279-288.
- Guo, Y., Li, J. & Cheng, X. (1999). [Discovery of men infected by avian influenza A (H9N2) virus]. *Zhonghua shi yan he lin chuang bing du xue za zhi= Zhonghua shiyan he linchuang bingduxue zazhi= Chinese journal of experimental and clinical virology*, 13(2): 105-108.
- Gupta, C. N., Palaniappan, R., Swaminathan, S. & Krishnan, S. M. (2007). Neural network classification of homomorphic segmented heart sounds. *Applied Soft Computing*, 7(1): 286-297.
- Gutierrez, W., Kim, S., Kim, D., Yeon, S. & Chang, H. (2010). Classification of porcine wasting diseases using sound analysis. *Asian-Australasian Journal of Animal Sciences*, 23(8): 1096-1104.
- Haryanto, A., Irianingsih, S. H., Yudianingtyas, D. W., Wijayanti, N. & Budipitojo, T. (2013). Single step multiplex RT-PCR for detection and differential diagnosis of avian influenza, newcastle disease and infectious bursal disease viruses in chicken. *Int Res J Biotechnol*, 4: 34-39.
- Haryanto, A., Purwaningrum, M., Verawati, S., Irianingsih, S. H. & Wijayanti, N. (2015). Pathotyping of Local Isolates Newcastle Disease Virus from Field Specimens by RT-PCR and Restriction Endonuclease Analysis. *Procedia Chemistry*, 14: 85-90.
- Hsu, C.-W. & Lin, C.-J. (2002). A comparison of methods for multiclass support vector machines. *Neural Networks, IEEE Transactions on*, 13(2): 415-425.
- Ionescu, R. & Llobet, E. (2002). Wavelet transform-based fast feature extraction from temperature modulated semiconductor gas sensors. *Sensors and Actuators B: Chemical*, 81(2): 289-295.
- Iyer, S., Sinha, S.K., Tittmann, B.R. & Pedrick, M.K. (2012). *Ultrasonic signal processing methods for detection of defects in concrete pipes*, Automation in Construction, 22: 135-148.
- Kasten, E. P., P. K. McKinley, *et al* (2010). Ensemble extraction for classification and detection of bird species. *Ecological Informatics*, 5(3): 153-166.
- Khazaei, M., Ahmadi, H., Omid, M., Banakar, A. & Moosavian, A. (2013). Feature-level fusion based on wavelet transform and artificial neural network for fault diagnosis of planetary gearbox using acoustic and vibration signals. *Insight-Non-Destructive Testing and Condition Monitoring*, 55(6): 323-330.
- Klir, G. J. & Wierman, M. J. (1999). *Uncertainty-based information: elements of generalized information theory*, Springer Science & Business Media.
- Lee, J., Jin, L., Park, D., Chung, Y. & Chang, H.-H. (2015). Acoustic Features for Pig Wasting Disease Detection. *International Journal of Information Processing and Management*, 6(1): 37.
- Lee, J. J., Lee, S. M., Kim, I. Y., Min, H. K. & Hong, S. H. (1999). Comparison between short time Fourier and wavelet transform for feature extraction of heart sound. *TENCON 99. Proceedings of the IEEE Region 10 Conference*, IEEE.
- Lei, Y., He, Z. & Zi, Y. (2008). A new approach to intelligent fault diagnosis of rotating machinery. *Expert Systems with Applications*, 35(4): 1593-1600.
- Lin, Y., Shaw, M., Gregory, V., Cameron, K., Lim, W., Klimov, A., Subbarao, K., Guan, Y., Krauss, S. & Shortridge, K. (2000). Avian-to-human transmission of H9N2 subtype influenza A viruses: relationship between H9N2 and H5N1 human isolates. *Proceedings of the National Academy of Sciences*, 97(17): 9654-9658.
- Malik, Y. S., Patnayak, D. P. & Goyal, S. M. (2004). Detection of three avian respiratory viruses by single-tube multiplex reverse transcription-polymerase chain reaction assay. *Journal of veterinary diagnostic investigation*, 16(3): 244-248.
- Marchant, B. (2003). Time-frequency analysis for biosystems engineering. *Biosystems engineering*, 85(3): 261-281.
- Misiti, M., Misiti, Y., Oppenheim, G. & Poggi, J.-M. (1996). *Wavelet toolbox. The MathWorks Inc., Natick, MA*.
- Morgan, H. (1946). Newcastle Disease Of Poultry. *Iowa State University Veterinarian*, 9(1): 4.
- Naeem, K., Ullah, A., Manvell, R. & Alexander, D. (1999). Avian influenza A subtype H9N2 in poultry in Pakistan. *Veterinary Record*, 145(19): 560-560.
- Nidzworski, D., Wasilewska, E., Smietanka, K., Szewczyk, B. & Minta, Z. (2013). Detection and differentiation of Newcastle disease virus and influenza virus by using duplex real-time PCR. *Acta Biochimica Polonica*, 60(3): 475-480.
- Parsons, S. & Jones, G. (2000). Acoustic identification of twelve species of echolocating bat by discriminant function analysis and artificial

- neural networks. *Experimental Biology*, 203(17): 2641-2656.
- Peiris, M., Yuen, K., Leung, C., Chan, K., Ip, P., Lai, R., Orr, W. & Shortridge, K. (1999). Human infection with influenza H9N2. *The Lancet*, 354(9182): 916-917.
- Ruhm, K. H. (2007). Sensor fusion and data fusion—Mapping and reconstruction. *Measurement*, 40(2): 145-157.
- Saravanan, N. & Ramachandran, K. (2010). Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN). *Expert Systems with Applications*, 37(6): 4168-4181.
- Schalk, A. & Hawn, M. (1931). An apparently new respiratory disease of baby chicks. *J. Am. Vet. Med. Assoc.*, 78(413-422): 19.
- Sentz, K. & Ferson, S. (2002). Combination of evidence in Dempster-Shafer theory, Citeseer.
- Shafer, G. (1976). mathematical theory of evidence, Princeton university press Princeton.
- Shafer, G. (2013). Probability Judgement in Artificial Intelligence. *arXiv preprint arXiv:1304.3429*.
- Simmonds, E. J., Armstrong, F. & Copland, P.J. (1996). Species identification using wideband backscatter with neural network and discriminant analysis. *ICES Journal of Marine Science*, 53: 189-195.
- Turkoglu, I., Arslan, A. & Ilkay, E. (2003). An intelligent system for diagnosis of the heart valve diseases with wavelet packet neural networks. *Computers in Biology and Medicine*, 33(4): 319-331.
- Vasfi Marandi, M. & Bozorgmehri Fard, M. H. (2002). Isolation of H9N2 subtype of avian influenza viruses during an outbreak in chickens in Iran. *Iranian Biomedical Journal*, 6(1): 13-17.
- Wang, X., Makis, V. & Yang, M. (2010). A wavelet approach to fault diagnosis of a gearbox under varying load conditions. *Journal of Sound and Vibration*, 329(9): 1570-1585.
- Wu, J. D. & Liu, C. H. (2009). An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network. *Expert Systems with Applications*, 36(3): 4278-4286.
- Xia, J. F., Li, X. Y., Li, P. W., Qian, M. & Ding, X. X. (2007). Application of wavelet transform in the prediction of navel orange vitamin C content by near-infrared spectroscopy. *Agricultural Sciences in China*, 6(9): 1067-1073.
- Xu, C., Zhang, H., Peng, D. & Yu, Y. (2012). Study of fault diagnosis of integrate of DS evidence theory based on neural network for turbine. *Energy Procedia*, 16: 2027-2032.
- Yager, R. R. (1987). On the Dempster-Shafer framework and new combination rules. *Information Sciences*, 41(2): 93-137.
- Zhan, Y. & Makis, V. (2006). A robust diagnostic model for gearboxes subject to vibration monitoring. *Journal of Sound and Vibration*, 290(3): 928-955.
- Zhu, D.-q. (2002). Data fusion algorithm based on DS evidential theory and its application for circuit fault diagnosis. *Acta electronica sinica*, 30(2): 221-223.
- Zhu, D., Ji, B., Meng, C., Shi, B., Tu, Z. & Qing, Z. (2007). Study of wavelet denoising in apple's charge-coupled device near-infrared spectroscopy. *Journal of agricultural and food chemistry*, 55(14): 5423-5428.
- Zhu, K., Wong, Y. S. & Hong, G. S. (2009). Wavelet analysis of sensor signals for tool condition monitoring: a review and some new results. *International Journal of Machine Tools and Manufacture*, 49(7): 537-553.