

ORIGINAL RESEARCH PAPER

Modeling and Weighting of Factors Affecting Sustained Attention and Working Memory of Workers Exposed to Different Sound Pressure Levels using Deep Learning and Random Forest Algorithms: A Case Study of a Steel Industry

Sajad Zare¹, Reza Esmaeili^{2,*}, Fardin Zandsalimi³

¹Department of Occupational Health Engineering and Safety at Work, Faculty of Public Health, Kerman University of Medical Sciences, Kerman, Iran

²Student Research Committee, Department of Occupational Health and Safety Engineering, School of Health, Isfahan University of Medical Sciences, Isfahan, Iran

³Department of Occupational Health and Safety Engineering, Faculty of Health, Kurdistan University of Medical Science, Sanandaj, Iran

Received: 2024-7-19

Accepted: 2024-09-19

ABSTRACT

Introduction: Cognitive functions play a vital role in how tasks are performed; for this, temporary cognitive and mental dysfunctions could lead to grave consequences, especially when an accurate and prompt response is required. Attention and reaction time to noise are among the most effective exogenous factors on the brain processing mechanism. This study aimed to measure the sustained attention of workers in the steel industry exposed to different sound pressure levels.

Material and Methods: The study was conducted in 4 general stages, including 1- Selecting predictive orientation variables (age, work history, different sound pressure levels); 2- Conducting the Cognitive Performance Test (CPT); 3 Conducting N-BACK Cognitive Performance Test and 4- Modeling cognitive performance changes using model precision methods.

Results: Continuous Performance Test (CPT) results indicated that all three groups' omission error, commission error, and response time were affected by shift time. All three components increased significantly as the shift ended, decreasing individuals' cognitive function. Also, the higher noise impact in modeling CPT and N-Back tests indicated reduced workers' concentration.

Conclusion: These study findings suggested that greater noise weight obtained in test modeling in three-time intervals, i.e., in the beginning, middle, and end of the shift, affected the continuous performance components of the CPT and working memory performance of the N-back test, including workers' response time and reaction time, with workers' rate of error increasing and their focus decreasing during the shift.

Keywords: Modeling, Sustained attention, Deep learning, Random forest, Noise

HOW TO CITE THIS ARTICLE

Zare S., Esmaeili R., Zandsalimi F. Modeling and Weighting of Factors Affecting Sustained Attention and Working Memory of Workers Exposed to Different Sound Pressure Levels using Deep Learning and Random Forest Algorithms: A Case Study of a Steel Industry. *J Health Saf Work.* 2024; 14(3): 482-502.

1. INTRODUCTION

Noise is a significant stressor affecting both physical and mental health worldwide. It impairs cognitive functions, leading to inattention, fatigue,

and speech comprehension issues. Studies show that noise negatively impacts cognitive performance, especially during prolonged exposure. Various techniques, such as EEG assessment and cognitive tests (N-BACK, CPT), evaluate workers' cognitive

* Corresponding Author Email: rezaesmaeili794@yahoo.com

abilities. However, limited research has modeled cognitive changes in noise-exposed workers. Many studies have been conducted in Iran and around the world on the effect of noise on cognitive functions; however, scant research has modeled and predicted cognitive function changes and physiological parameters among workers exposed to noise. Thus, this study was developed to investigate the following objectives:

- Measuring the Equivalent Continuous Sound Pressure Level among workers in steel industry environments
- Determining workers' cognitive performance at the beginning, middle, and end of the shifts based on N-BACK and CPT tests
- Determining the relationship between sound pressure levels and workers' cognitive functions at the shifts' beginning, middle, and end.
- Determining factors affecting the cognitive performance of workers
- Determining the weight of the factors affecting the cognitive performance of workers based on Deep Learning and Random Forest algorithms

2. MATERIAL AND METHODS

In this cross-sectional study, 120 people were selected and divided into three groups (one control group and two case groups) via a Simple Random Sampling method. Participants were divided into one of the following three groups based on their exposure to different sound pressure levels:

- The first group includes people exposed to a sound pressure level of less than 75 dB (control group)
- The second group includes people exposed to sound pressure levels between 75 and 85 dB (first case group)
- The third group includes people exposed to sound pressure levels higher than 85 dB (second case group)

The study was conducted in 4 general stages, including 1- Selecting predictive orientation variables (age, work history, different sound pressure levels); 2- Conducting the Cognitive Performance Test (CPT); 3 Conducting the N-BACK Cognitive Performance Test; and 4- Modeling cognitive performance changes using model precision methods.

To avoid the effects of learning on the study's results, subjects were given practical training in working with software before the main test. In this study, workers' predictive and cognitive

performance parameters were evaluated at the shifts' beginning, middle, and end, and cognitive performance changes were modeled by Deep Learning and Random Forest data mining algorithms for all three time intervals. The studied participants were selected considering the following inclusion criteria: 1: No diagnosis of cardiovascular diseases; 2: evidence of any mental disorders; 3: Not regularly drinking caffeinated beverages; 4: No drug addiction and smoking; 5: Having a healthy hearing; 6: sleep disorders; 7: major systemic diseases. To assure that all ethical rules have been observed in human research, the research objectives were discussed with all subjects willing to participate in the project, and a written consent form was obtained from them.

Equivalent Continuous Sound Pressure Level (Leq) variables, i.e., working experience and age, were considered for each individual. The cognitive functions were assessed using Continuous Performance Test (CPT) and Visual and auditory test (N-BACK). The CPT measures sustained attention and alertness of the individual's auditory and visual systems. The N-BACK test measures peoples' visual and auditory memory. Using Deep Learning and Random Forest algorithms the Modeling of changes in cognitive function was performed. After developing the models, Precision evaluation and the AUCs of developed models were done.

This study was approved by the ethics committee of Kerman University of Medical Sciences with code number IR.KMU.REC 1398.635. The collected data were analyzed using Statistical Package for Social Sciences V.18 (SPSS) (SPSS, Inc., Chicago, Illinois, USA).

3. RESULTS AND DISCUSSION

Demographic Information

The mean age was 36.23 ± 2.75 , 32.03 ± 3.51 , and 32.03 ± 3.51 for the three studied groups, respectively. The mean working experience was 9.10 ± 2.05 , 7.03 ± 2.30 , and 7.03 ± 2.30 , respectively. The mean metabolism were 110.7 ± 1.06 , 154.1 ± 1.32 , and 178 ± 1.25 watt/M2, respectively.

Average Equivalent Continuous Sound Pressure Level (SPL)

The control group was exposed to the average Equivalent Continuous Sound Pressure Level of 70.3 ± 1.32 dB, while the workers in the experimental group were exposed to the average level of 80.97 ± 1.89 and 93.86 ± 1.69 dB, respectively.

Continuous Performance Test (CPT)

Table 1 shows the average commission error, omission error, and response time of the workers of all 3 groups at the shift's beginning, middle and end. According to the results of Table 1, at the end of the shift, the commission error is significantly affected. Also, there was a statistically significant difference in the average equivalent sound level on the omission error in the middle and at the end of the shift. In addition, the average equivalent sound level significantly affected the response time of workers in the middle and end of the shift.

Working Memory Test (N-back)

Table 2 shows the results of the reaction time and the Mean of correct answer at the beginning, middle, and end of the shift, based on which it was determined that the average equivalent sound level significantly affects the reaction time and the correct answer of the workers in the middle and end of the shift.

Modeling using Deep Learning and Random Forest Algorithms

Modeling results from Deep Learning and

Random Forest algorithms concerning omission and commission errors, response time, reaction time, and correct answers are illustrated in Table 3. For omission error, According to the modeling results with the Random Forest algorithm, the weight of Leq at the beginning, middle, and end of the shift are 35.9, 31.51, and 45.46, respectively. Additionally, the Deep Learning algorithm modeling results showed that the weight of Leq at the beginning, middle, and end of the shift are 32.47, 31.74, and 44.37, respectively. For commission error, The weight of the Leq variable, according to the results obtained from the Random Forest algorithm, is 34.33, 38.09, and 33.33 for the beginning, middle, and end of the shift, respectively. Additionally, the Deep Learning algorithm indicated that the weight of the Leq variable for the beginning, middle, and end of the shift is 32.5, 35.67, and 34.12, respectively. For response time, the weight of the Leq variable, according to the results obtained from the Random Forest algorithm, is 22.47, 24.99, and 29.99 for the beginning, middle, and end of the shift, respectively.

Additionally, the Deep Learning algorithm indicated that the weight of the Leq variable for

Table 1: Commission error, omission error and response time of workers of all 3 groups at the beginning, middle and end of the shift

| Variable | Group | Beginning of the shift | | Middle of the shift | | End of the shift | |
|------------------|---------|------------------------|------|---------------------|------|------------------|------|
| | | Mean | SD | Mean | SD | Mean | SD |
| Commission error | Group 1 | 0.7 | 0.15 | 0.6 | 0.09 | 3 | 0.25 |
| | Group 2 | 1.25 | 0.32 | 2 | 0.21 | 1.75 | 0.33 |
| | Group 3 | 1.8 | 0.27 | 3.2 | 0.46 | 3.9 | 0.58 |
| | P-Value | 0.12 | | 0.057 | | 0.032 | |
| Omission error | Group 1 | 1.7 | 0.26 | 1.4 | 0.17 | 0.5 | 0.12 |
| | Group 2 | 1.4 | 0.17 | 1.75 | 0.23 | 1.5 | 0.15 |
| | Group 3 | 2 | 0.15 | 3.4 | 0.32 | 3.75 | 0.38 |
| | P-Value | 0.45 | | 0.002 | | 0.001 | |
| Response time | Group 1 | 420 | 22 | 415 | 26 | 427 | 18 |
| | Group 2 | 450 | 19 | 435 | 12 | 465 | 12 |
| | Group 3 | 470 | 12 | 475 | 32 | 490 | 37 |
| | P-Value | 0.25 | | 0.001 | | 0.001 | |

Table 2: Reaction time and correct answer in all three studied groups at the beginning, middle and end of the shift

| Variable | Group | Beginning of the shift | | Middle of the shift | | End of the shift | |
|----------------|---------|------------------------|----|---------------------|----|------------------|----|
| | | Mean | SD | Mean | SD | Mean | SD |
| Reaction time | Group 1 | 540 | 15 | 580 | 29 | 605 | 37 |
| | Group 2 | 555 | 34 | 585 | 32 | 627 | 38 |
| | Group 3 | 570 | 37 | 600 | 41 | 540 | 52 |
| | P-Value | 0.38 | | 0.035 | | 0.001 | |
| Correct answer | Group 1 | 80 | 11 | 89 | 10 | 79 | 9 |
| | Group 2 | 78 | 4 | 70 | 15 | 64 | 12 |
| | Group 3 | 75 | 6 | 68 | 9 | 58 | 7 |
| | P-Value | 0.45 | | 0.001 | | 0.001 | |

Table 3: Modeling results of Deep Learning and Random Forest algorithms for Omission and Commission Errors

| Test | Variable (Weight) | Group 1 | | Group 2 | | Group 3 | |
|-------------------------|-------------------|---------------------|-------|---------------------|-------|---------------------|-------|
| | | Modelling Algorithm | | Modelling Algorithm | | Modelling Algorithm | |
| | | R f | DL | R f | DL | R f | DL |
| Omission error | Leq | 35.9 | 32.47 | 31.51 | 31.74 | 45.46 | 44.37 |
| | Experience | 23.08 | 22.25 | 12.33 | 11.81 | 14.55 | 15.12 |
| | Age | 20.5 | 19.92 | 12.33 | 13.23 | 12.71 | 11.91 |
| | Metabolism | 10.26 | 14.3 | 23.28 | 20.75 | 14.55 | 13.11 |
| | BMI | 10.26 | 11.06 | 20.55 | 22.47 | 12.73 | 15.49 |
| Accuracy | 94% | 93% | 91% | 87% | 90% | 91% | |
| Commission error | Leq | 33.34 | 32.5 | 38.09 | 35.67 | 33.33 | 34.12 |
| | Experience | 25 | 26.25 | 7.14 | 8.23 | 19.05 | 18.75 |
| | Age | 12.5 | 13.5 | 15.48 | 14.76 | 14.29 | 13.98 |
| | Metabolism | 12.5 | 11.75 | 25 | 26.32 | 16.67 | 15.45 |
| | BMI | 16.66 | 16 | 14.29 | 15.02 | 16.66 | 17.7 |
| Accuracy | 88% | 97% | 87% | 90% | 87% | 92% | |
| Response time | Leq | 47.22 | 46.78 | 24.99 | 25 | 29.99 | 28.75 |
| | Experience | 8.33 | 7.92 | 2.09 | 2.1 | 9.99 | 8.5 |
| | Age | 25 | 24.53 | 39.58 | 39.6 | 26.68 | 27.25 |
| | Metabolism | 11.11 | 10.77 | 14.58 | 14.5 | 3.35 | 5 |
| | BMI | 8.34 | 9 | 18.76 | 18.80 | 29.99 | 31.5 |
| Accuracy | 96% | 89% | 91% | 95% | 91% | 89% | |
| Reaction time | Leq | 43.64 | 42.50 | 44.44 | 31.74 | 39.99 | 38.50 |
| | Experience | 21.81 | 22.30 | 11.11 | 11.81 | 9.99 | 10.25 |
| | Age | 14.55 | 13.75 | 11.12 | 13.23 | 13.35 | 14 |
| | Metabolism | 9.1 | 8.85 | 7.41 | 20.75 | 6.68 | 7.25 |
| | BMI | 10.9 | 12.60 | 25.92 | 22.47 | 29.99 | 30 |
| Accuracy | 99% | 93% | 96% | 92% | 91% | 89% | |
| Correct answer | Leq | 16.27 | 17 | 27.39 | 26.50 | 26.86 | 26.50 |
| | Experience | 27.9 | 28.50 | 21.93 | 22.50 | 22.39 | 22 |
| | Age | 11.62 | 12.03 | 9.59 | 10 | 7.46 | 7.75 |
| | Metabolism | 18.6 | 17.97 | 19.18 | 18.75 | 17.92 | 18 |
| | BMI | 25.58 | 24.50 | 21.19 | 22.25 | 25.37 | 25.75 |
| Accuracy | 99% | 93% | 96% | 95% | 91% | 89% | |

the beginning, middle, and end of the shift is 46.78, 25.00, and 28.75, respectively. For reaction time, according to the results obtained from modeling with the Random Forest algorithm, the weight of Leq at the beginning, middle, and end of the shift is 43.64, 44.44, and 39.99, respectively.

Additionally, the results from modeling with the Deep Learning algorithm showed that the weight of Leq at the beginning, middle, and end of the shift is 42.50, 45.00, and 38.50, respectively. For the correct answer, according to the results obtained from modeling with the Random Forest algorithm, the Body Mass Index (BMI) weight at the shift's beginning, middle, and end of the shift is 25.58, 21.91, and 25.37, respectively. Additionally, the results from modeling with the Deep Learning algorithm indicated that the weight of the Body Mass Index (BMI) at the beginning, middle, and end of the shift is 24.50, 22.25, and 25.75, respectively.

In this study, sustained attention changes and physiological responses of workers exposed to different sound pressure levels at the beginning, middle and end of shifts were modeled using Deep Learning and Random Forest algorithms. Continuous Performance Test (CPT) results suggested that omission error, commission error, and reaction time among all three groups were affected by shift time intervals, with all three components significantly increasing at the end of the shift; in other words, workers' cognitive functions decreased. The weight of the variables of Leq, age, work experience, BMI, and metabolism for each of the CPT and N-Back tests were calculated at the shifts' beginning, middle, and end.

The advantage of the present study is the use of data mining algorithms to classify and weigh the impact of factors affecting the results of N-BACK and CPT tests. Using such algorithms increases the study's accuracy compared to conventional

statistical methods. The most important limitation of the present study can be considered as its cross-sectional design and lack of cooperation of employees due to interference in their routine tasks. It is suggested that future studies, research be conducted longitudinally and with more participants and in different occupations.

4. CONCLUSIONS

The findings of this study demonstrated that higher noise weight values in test modeling during three-time intervals, i.e., in the beginning, middle, and end of the shift, affected continuous performance and working memory performance components, including workers' response time and reaction time, with the workers' error rate increasing

and their attention decreasing during the shift. On the other hand, due to the high job sensitivity of steelworkers, their number and exposure to various hazardous agents, as well as unsafe environmental conditions, their cognitive impairment could entail grave consequences safety and control strategies are warranted to remove the challenges. Therefore, safety and health managers can use the present study to run an effective strategy and improve the cognitive functions of different groups of on-duty workers.

5. ACKNOWLEDGMENT

We would like to express our indebtedness to Research Institute for Future Studies in the Kerman University of Medical Sciences

مدلسازی و وزن دهی عوامل موثر بر توجه پایدار متمرکز و حافظه کاری کارگران مواجهه یافته با ترازهای مختلف فشار صوت با استفاده از الگوریتم های Deep Learning و Random Forest: مطالعه موردی یک صنعت فولاد

سجاد زارع^۱، رضا اسمعیلی^{۲*}، فردین زندسلیمی^۳

^۱گروه مهندسی بهداشت حرفه ای و ایمنی کار، دانشکده بهداشت، دانشکاه علوم پزشکی کرمان، کرمان، ایران.
^۲کمیته تحقیقات دانشجویی، گروه مهندسی بهداشت حرفه ای و ایمنی کار، دانشکده بهداشت، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

^۳گروه مهندسی بهداشت حرفه ای و ایمنی کار، دانشکده بهداشت، دانشگاه علوم پزشکی کردستان، سنندج، ایران

تاریخ دریافت: ۱۴۰۳/۴/۲۹، تاریخ پذیرش: ۱۴۰۳/۶/۲۹

چکیده

مقدمه: عملکردهای شناختی نقش حیاتی در عملکرد بسیاری از وظایف بازی می کنند؛ بنابراین اختلال موقت در عملکرد شناختی و ذهنی می تواند منجر به عواقب جدی گردد، به ویژه هنگامی که پاسخ دقیق و فوری نیاز است. یکی از مؤثرترین عوامل برونزاد تأثیرگذار بر مکانیسم پردازشی مغز، توجه و زمان واکنش صدا است. بنابراین، این مطالعه طراحی گردید تا توجه پایدار متمرکز کارگران صنایع فولاد مواجهه یافته با ترازهای فشار صوت مختلف را بسنجد که در نتیجه راندمان و بهره وری کار افزایش خواهد یافت.

روش کار: مطالعه در ۴ مرحله کلی انجام شد که به ترتیب عبارتند از ۱- انتخاب متغیرهای پیش بین جهت (سن، سابقه کار، ترازهای مختلف فشار صوت) ۲- انجام آزمون عملکرد پیوسته (CPT) ۳- انجام آزمون عملکرد شناختی N- BACK ۴- مدل سازی تغییرات عملکرد شناختی بر اساس هر دو روش و تعیین نرخ خطا و صحت هر مدل.

یافته ها: نتایج آزمون عملکرد پیوسته نشان داد که خطای حذف، خطای ارتکابی و زمان پاسخگویی هر سه گروه تحت تأثیر زمان شیفت قرار می گیرند، هر سه مولفه به طور معنی داری در انتهای شیفت افزایش یافتند، به عبارتی عملکرد شناختی افراد کاهش یافت. همچنین تأثیر بالای صدا در مدلسازی های آزمون های CPT و N- Back بیانگر کاهش تمرکز و حواس پرتی کارگران ناشی از آن است.

نتیجه گیری: نتایج این پژوهش نشان داد که با توجه به وزن بالای به دست آمده از صدا در مدلسازی های آزمون ها، در سه زمان ابتدا، وسط و انتهای شیفت بر مولفه های عملکرد پیوسته (CPT) و عملکرد حافظه کاری (n-back) از جمله زمان پاسخگویی و زمان واکنش کارگران اثر می گذارد و در طول شیفت میزان خطای کارگران افزایش و دقت آنها کاهش می یابد.

کلمات کلیدی: مدلسازی، توجه پایدار، Random Forest، Deep Learning، صوت

1. Continues performance test (CPT)

* پست الکترونیکی نویسنده مسئول مکاتبه: rezaesmaeili794@yahoo.com

مقدمه

صدا منبع مهم تنش فیزیکی و روانی است که مهم‌ترین عامل زیان‌آور فیزیکی در کشورهای توسعه یافته و در حال توسعه دانسته می‌شود (۱). در ایالات متحده، بیش از ۳۰ میلیون کارگر در مواجهه با صدای خطرناک هستند (۲). به طوری که در کشور آلمان، حدود ۴ تا ۵ میلیون کارگر طبق استاندارد سازمان جهانی بهداشت در مواجهه با تراز فشار صوت بیش از حد هستند (۳). محیط پرصدا موجب بی‌دقتی در فعالیت‌های مغزی و ناهماهنگی در کارهای فکری می‌شود. صدا عامل استرس زای محیطی بوده و در ترکیب با سایر عوامل استرس‌زا باعث ایجاد یا تشدید اختلالات روانی می‌گردد و حتی تحت شرایط خاص کارایی را تحت تأثیر قرار می‌دهد (۴-۸)؛ تا جایی که سازمان جهانی بهداشت حوادث را یکی از شاخص‌های کاهش عملکرد ناشی از صدا می‌داند و صدای محیط را عامل مستقیم اختلالات ذهنی می‌شناسد. صدا می‌تواند عملکرد شناختی افراد را از طریق ایجاد عدم احساس آسایش، خستگی، آشفتگی و بیهوشی دست‌خوش تغییر نماید و موجب بی‌دقتی در فعالیت‌های ذهنی، تأثیرات قلبی-عروقی اختلال در کارهای فکری و همچنین باعث اختلال در مکالمات و تفهیم آن‌ها می‌شود (۸، ۹).

شاخص‌هایی عملکرد روانی - ذهنی نشان‌دهنده وضعیت شناختی فرد می‌باشد. منظور از شناخت، کارکردهای عالی در مغز انسان است. از جمله شاخص‌های شناختی مهم در انسان، حافظه، تمرکز، تکانش‌گری، آگاهی از زمان و مکان، حل مسئله و توانایی دیداری می‌باشد (۱۰). عملکردهای شناختی، مانند: حافظه کاری، توجه، سرعت پردازش اطلاعات و غیره نقش حیاتی در عملکرد بسیاری از وظایف بازی می‌کنند؛ بنابراین اختلال موقت در عملکرد شناختی و ذهنی می‌تواند منجر به عواقب جدی گردد، به ویژه هنگامی که پاسخ دقیق و فوری نیاز است (۱۱). همچنین مطالعات میدانی و آزمایشگاهی نشان داد سروصدا بر توانایی‌های شناختی مختلف بدن تأثیر منفی می‌گذارد (۱۲، ۱۳). علاوه بر این، سروصدا

اثرات گسترده‌ای، از تداخل با پردازش شناختی تا اثرات مضر بر سلامت روانی و جسمی دارد. سروصدا با تداخل با پردازش اطلاعات عملکرد شناختی را مختل می‌کند (۱۴). عملکردهای شناختی از قبیل توجه پایدار، درک، سرعت عکس‌العمل و همچنین پردازش صحیح اطلاعات و تصمیم‌گیری درست در انجام بسیاری از وظایف نقش اساسی دارد (۱۴). همچنین، مواجهه با سطوح خطرناک صدا، ممکن است بر سیستم عصبی مرکزی و مغز تأثیر بگذارد و در نتیجه منجر به افزایش خطر اختلالات عصبی-روان پزشکی مانند سکته مغزی، زوال عقل، زوال شناختی، اختلالات رشد عصبی، افسردگی و اختلال اضطراب شود (۱۵، ۱۶). که آسیب سیستم عصبی مرکزی می‌تواند ناشی از عوامل مختلفی نظیر استرس اکسیداتیو در گیرنده‌های شنوایی مغز، آسیب انتقال‌دهنده‌های عصبی، تغییر سطوح مولکولی مغز و تغییر مورفولوژی مغز ناشی از مواجهه با سطوح بالای صدا باشد (۱۶).

طبق بررسی انجام شده در یک مطالعه جامع مروری، از ۵۸ مطالعه صورت گرفته در زمینه‌ی اثرات صدا بر عملکرد شناختی انسان در ۲۹ مطالعه اثرات صدا منفی بود و در ۲۲ مطالعه صدا بر عملکرد ذهنی تأثیری نداشت و در ۷ مطالعه دارای تأثیر مثبت بود (۱۷). مطالعات صورت گرفته نشان داده است که مواجهه محدود با صدا (بین ۲۰ تا ۶۰ دقیقه) توجه و زمان واکنش فعالیت‌های عملکردی و شناختی تأثیرگذار است (۱۸). سازمان بهداشت جهانی WHO^۱ میزان خسارت روزانه ناشی از صدا را در حدود ۴ میلیون دلار برآورد کرده است (۱۹). مطالعه‌ی chang sun sim و همکاران نشان داده است که ۳۴/۵ درصد کل شکایت‌های محیط زیستی کشور کره جنوبی مربوط به صدا است (۲۰). کیفیت صدا یکی از عوامل مهمی است که افراد در مواجهه با صدا را تحت تأثیر قرار می‌دهد (۲۱-۲۳) و پاسخ به صدا ممکن است به ویژگی‌های صدا که شامل فرکانس، تراز فشار صوت، پیچیدگی صوت، مدت‌زمان و بلندی صدا هستند بستگی داشته باشد (۲۴، ۲۵).

1. world Health Organization

استفاده از الگوریتم‌های یادگیری ماشین مانند deep learning (DL) موفقیت زیادی در گستره استفاده از بازی‌های کامپیوتری، شناسایی صدا، کامپیوتر دیداری، فرایند زبان طبیعی، ماشین‌های خودران و چیزهای دیگر پیدا کرد (۳۳). در بین روند ۱۰ تکنولوژی برتر سال ۲۰۱۷، تکنولوژی DL، بیشترین امتیاز را آورد (۳۴). DL کلاسی از الگوریتم‌های یادگیری ماشین است که از شبکه عصبی مصنوعی (ANN) همراه با تعداد زیادی لایه‌های غیرخطی برای ارائه یادگیری داده‌ها استفاده می‌کند. اولین شبکه عصبی به سال ۱۹۴۳ برمی‌گردد که Warren McCulloch و Walter Pitts مدلی محاسباتی برای شبکه عصبی بر پایه ریاضیات و الگوریتم‌ها نوشتند (۳۵، ۳۶).

در طول دهه‌های اخیر، مطالعات زیادی در ایران و جهان بر روی تأثیر صدا بر عملکرد شناختی انسان انجام شده است. این پژوهش‌ها عمدتاً به بررسی تأثیرات کلی صدا بر روی تمرکز و حافظه پرداخته‌اند. با این حال، پژوهش‌های کمی وجود دارد که به مدل‌سازی و پیش‌بینی تغییرات عملکرد شناختی و پارامترهای فیزیولوژیکی کارگران در مواجهه با ترازهای مختلف فشار صوت بپردازند. این کمبود پژوهشی به ویژه در صنایع سنگین مانند صنعت فولاد محسوس است، جایی که کارگران به طور مداوم در معرض سطوح بالای فشار صوت قرار دارند. از این رو، این مطالعه به منظور پر کردن این خلأ علمی و کاربردی طراحی شده است. بنابراین، این مطالعه طراحی گردید تا اهداف زیر را بررسی کند:

- اندازه‌گیری تراز معادل مواجهه با صدا در محیط‌های کاری کارگران صنعت فولاد
- تعیین عملکرد شناختی کارگران در ابتدا، وسط و انتهای شیفت بر اساس آزمون‌های N-BACK و CPT
- تعیین ارتباط بین ترازهای مختلف فشار صوت با عملکرد شناختی کارگران در ابتدا، وسط و انتهای شیفت.
- تعیین عوامل مؤثر بر عملکرد شناختی کارگران
- تعیین وزن عوامل مؤثر بر عملکرد شناختی کارگران بر اساس الگوریتم‌های یادگیری عمیق و جنگل تصادفی.

داده کاوی^۱ (DM) عبارت است از جستجوی خودکار منابع داده ای بزرگ، جهت یافتن الگوها و وابستگی هایی که تحلیل های ساده آماری قادر به انجام آنها نیستند. فرآیند استخراج اطلاعات معتبر، از پیش‌ناشناخته، قابل فهم و قابل اعتماد از پایگاه داده های بزرگ و استفاده از آن در تصمیم گیری در فعالیت های تجاری مهم است. داده کاوی فراتر از جمع آوری و مدیریت داده است و شامل تجزیه، تحلیل و پیشگویی می شود. نام دیگر آن کشف دانش در پایگاه داده یا به اختصار KDD^۲ است (۲۶). داده کاوی ابزاری است برای به دست آوردن اطلاعاتی از سری داده های یک مجموعه و شامل مراحل مختلفی است از جمله: ۱- انتخاب متغیرهای مورد نظر ۲- پیش‌پردازش داده ها ۳- استفاده از تکنیک های متنوع داده کاوی ۴- اطلاعات استخراجی ۵- تفسیر داده ها. تکنیک های متنوعی از داده کاوی در زمینه‌های طبقه بندی، پیش‌بینی، انجمنی، خوشه بندی و تجزیه تحلیل‌های پی‌درپی وجود دارد (۲۷). داده کاوی همچنین به طور گسترده در پزشکی استفاده می‌شود. DM به طور خاص در ادیولوژی برای طبقه بندی سطوح افت شنوایی در کودکان و بیماران دارای سندروم منیر^۳ استفاده می‌شود (۲۸، ۲۹).

امروزه مطالعات داده کاوی مختلفی به منظور مدیریت داده های مرتبط با سیستم شنوایی علی الخصوص داده‌های مربوط به سیستم شنوایی افراد در سیستم‌های بهداشت و درمان شغلی مرتبط با صنایع انجام گردیده است (۳۰-۳۲). به طور مثال در مطالعه فرهادیان و همکاران از الگوریتم شبکه عصبی و رگرسیون لجستیک برای ارزیابی و مدیریت داده‌های مربوط به نقص در سیستم شنوایی و عملکرد در یک صنعت فولاد استفاده شد (۳۰). همچنین در مطالعه Noma, G و همکاران از الگوریتم FP-growth و شبکه‌های بیزین برای پیش‌بینی افت شنوایی در پرسنل و اختلال در سایر متغیرهای ذهنی استفاده شد (۳۱).

تقاضای بالا برای استخراج و آنالیز داده‌های زیاد باعث

1. Data mining
2. Knowledge discover in database
3. Meniere syndrome

روش کار

طراحی مطالعه

پژوهش حاضر یک مطالعه ی توصیفی _ تحلیلی از نوع مقطعی است، که با هدف مدل سازی و پیش بینی تغییرات عملکرد شناختی و پاسخ های فیزیولوژیکی کارگران مواجهه یافته با ترازهای مختلف فشار صوت با استفاده از الگوریتم های Deep Learning و Random Forest در یک صنعت فولاد در استاد کرمان انجام شد. در این پژوهش ۱۲۰ نفر از کارکنان صنعت فولاد مورد مطالعه انتخاب و به روش نمونه گیری تصادفی ساده در سه گروه (یک گروه کنترل و دو گروه مورد) قرار گرفتند. شرکت کنندگان بر اساس قرار گرفتن در معرض سطوح مختلف تراز فشار صوتی به یکی از سه گروه زیر تقسیم شدند:

- گروه اول شامل افراد شاغل در واحد اداری مجتمع است که در معرض تراز فشار صوت معادل (L_{eq}) کمتر از ۷۵ دسی بل قرار دارند (گروه کنترل).
 - گروه دوم شامل افراد شاغل در واحد ساخت مجتمع است که در معرض تراز فشار صوت معادل (L_{eq}) بین ۷۵ تا ۸۵ دسی بل قرار دارند (گروه مورد اول).
 - گروه سوم شامل افراد شاغل در واحد فولادسازی مجتمع است که در معرض تراز فشار صوت معادل (L_{eq}) بالاتر از ۸۵ دسی بل قرار دارند (گروه مورد دوم).
- مطالعه در ۴ مرحله کلی انجام شد که به ترتیب عبارتند از ۱- انتخاب متغیرهای پیش بین جهت (سن، سابقه کار، ترازهای مختلف فشار صوت معادل (L_{eq})) ۲- انجام آزمون عملکرد پیوسته ۳- انجام آزمون عملکرد شناختی N-BACK ۴- مدل سازی تغییرات عملکرد شناختی بر اساس هر دو روش و تعیین نرخ خطا و صحت هر مدل (۳۷). با توجه به اینکه شرکت کنندگان در مطالعه در طول ۸ ساعت با صدا مواجهه داشتند و این مواجهه در طول زمان می تواند تاثیرهای متفاوتی بر افراد داشته باشد، در این مطالعه پارامترهای پیش بین و عملکرد شناختی کارگران در ابتدای شیفت، وسط و انتهای شیفت مورد ارزیابی قرار گرفت و برای هر ۳ زمان مختلف تغییرات

عملکرد شناختی توسط الگوریتم های داده کاوی Deep Learning و Random Forest مدل سازی شد. افراد مورد مطالعه با در نظر گرفتن معیارهای ورود زیر مورد گزینش قرار گرفتند؛ ۱: عدم ابتلا به بیماری های قلبی و عروقی. ۲: برخورداری از سلامت روانی. ۳: عدم استفاده از نوشیدنی های کافئین دار به طور منظم. ۴: عدم استفاده از داروهای خواب آور. ۵: عدم اعتیاد به مواد مخدر و مصرف سیگار. ۶: برخورداری از سلامت شنوایی. به منظور رعایت اصول اخلاق در پژوهش های انسانی تمامی افراد مایل به شرکت در طرح ضمن در جریان قرار گرفتن در خصوص اهداف مطالعه حاضر رضایت کتبی خود را برای شرکت در این پژوهش اعلام خواهند نمود.

انتخاب متغیرهای مورد نظر (پیش بین)

مطابق مطالعات قبلی متغیرهای تراز معادل مواجهه با صوت (L_{eq})، سابقه کار و سن به عنوان متغیرهای اثرگذار اصلی و پیش بینی کننده برای هر یک از افراد در نظر گرفته شد (۳۷، ۳۸).

- سابقه کار

طبق مطالعات قبلی، افراد مطالعه بر حسب متغیر سابقه کار به سه گروه، افرادی با سابقه کار کمتر از ۱۰ سال، بین ۱۰ تا ۲۰ سال و بالای ۲۰ سال تقسیم شدند (۳۹).

- سن

طبق مطالعات قبلی، تمام افراد مورد مطالعه بزرگسال هستند و بر اساس این متغیر افراد به سه گروه سنی تقسیم می شوند. گروه اول سنی بین ۲۰ تا ۳۵ سال دارند، گروه دوم بین ۳۵ تا ۵۰ سال و سومین گروه سنی بالای ۵۰ سال دارند (۳۷).

- اندازه گیری تراز معادل مواجهه صوت

ارزیابی تراز معادل مواجهه صوت (equivalent sound level) با استفاده از دستگاه دزیتر صدا (noise

Lp_i : تراز معادل اندازه‌گیری شده در اتاق استراحت و محل کار افراد بر حسب dB

- متابولیسم

میزان متابولیسم شرکت کنندگان در سه گروه بر اساس ISO 8996 تعیین شد (۴۳). شرکت کنندگان در این مطالعه برنامه کاری یک هفته کار در روز، یک هفته کار شبانه و یک هفته تعطیل داشتند. اعضای کارکنان در کمپ‌هایی که توسط شرکت ساخته شده بود به دور از خانواده خود زندگی می‌کردند. در این مطالعه، روزهای کاری شامل یک شیفت ۱۲ ساعته بود که از ۷ صبح تا ۷ بعد از ظهر متغیر بود.

آزمون عملکرد پیوسته^۱ (CPT)

این آزمون به منظور سنجش توجه پایدار و گوش به زنگ بودن به صورت شنیداری و دیداری افراد کاربرد دارد. آزمون معتبری برای یافتن اختلال در عملکرد توجه پایدار می‌باشد. در این آزمون یک سری اعداد با فاصله زمانی معین ظاهر می‌شوند و یک محرک به عنوان محرک هدف تعیین می‌گردد. شرکت کنندگان باید با مشاهده اعداد مورد نظر هر چه سریع‌تر کلید مربوطه را بر روی صفحه رایانه فشار دهند. متغیرهای مورد سنجش در این آزمون عبارتند از ۱-: خطای حذف: فشار ندادن کلید هدف در برابر محرک ۲- خطای ارتکاب: فشار دادن کلید در برابر محرک غیر هدف ۳- زمان واکنش: میانگین زمان واکنش پاسخ‌های صحیح در برابر محرک بر حسب هزارم ثانیه (۴۴). از CPT برای سنجش خطای توجه و توجه پایدار استفاده شد. در پژوهش حاضر از نسخه فارسی معتبر ابزار استفاده شد. این آزمایش شامل ۱۵۰ محرک است که روی صفحه ظاهر می‌شود. وظیفه شرکت کنندگان این بود که به محض اینکه عدد "۴" روی صفحه نمایش داده شد، کلید فاصله را روی صفحه کلید خود فشار دهند. زمان ارائه برای هر محرک ۱۵۰ میلی ثانیه، با فاصله ۵۰۰ میلی ثانیه (میلی ثانیه) بین هر دو محرک بود. تعداد

(dosimeter) (دستگاه Casella مدل 320 Cel) و استاندارد ISO 9612 انجام شد به منظور کالیبره کردن دستگاه دزیمتری قبل از اندازه‌گیری، از کالیبراتور مدل Cel- 110/2 استفاده گردید. (۴۰، ۴۱). از آنجایی که افراد در واحدها به طور مداوم در حال کار بودند (به جز ساعت استراحت که برابر ۲ ساعت بود)، میزان مواجهه فردی آن‌ها در سایت به مدت ۶ ساعت اندازه‌گیری شد. در زمان استراحت نیز کارگران از سایت خارج و در سالن استراحت به رفع خستگی می‌پرداختند که میزان مواجهه با صدا نیز به مدت ۲ ساعت اندازه‌گیری و ثبت شد. روش محاسبه دز دریافتی صدا توسط کارگر و اندازه‌گیری تراز معادل مواجهه ۸ ساعته در زیر ذکر شده است: اندازه‌گیری دز دریافتی صدا توسط کارگر با استفاده از معادله زیر انجام شد (۴۲):

$$Dose(\%) = \frac{8}{T_a} \times 100 \quad (1)$$

که در آن:

D: دز صدا به درصد

T_a : مدت زمان مجاز مواجهه با توجه به تراز فشار صوت محیط (ساعت)

برای استاندارد مواجهه ایران نیز رابطه درصد دز بصورت زیر خواهد بود (۴۲):

$$D(\%) = 12.5 \sum_{i=1}^n t_i \text{antilog} \left(\frac{SPL_i - 85}{10} \right) \quad (2)$$

به منظور اندازه‌گیری تراز معادل مواجهه ۸ ساعته در واحدهای مورد بررسی از فرمول زیر استفاده گردید (۴۲):

$$Leq.8h (dB) = 10 \log \left[\frac{1}{8} \sum_{i=1}^n t_i \times 10^{\frac{Lp_i}{10}} \right] \quad (3)$$

که در آن:

$L_{eq.8h}$: تراز معادل مواجهه ۸ ساعته بر حسب dB

t_i : مدت زمان مواجهه‌های مربوطه بر حسب ساعت

(hr)

1. Continuous performance test

پاسخ‌های صحیح، خطای حذف، خطای ارتکاب و زمان پاسخ (بر حسب میلی ثانیه) به عنوان متغیرهای وابسته ثبت شد.

آزمون دیداری و شنیداری (N-BACK)

این آزمون برای سنجش حافظه دیداری و شنیداری افراد کاربرد دارد. این آزمون یک تکلیف سنجش عملکرد شناختی مرتبط با کنش‌های اجرایی است. از آن جا که این آزمون نگهداری اطلاعات شناختی و دست کاری آن‌ها را شامل می‌شود، برای سنجش عملکرد حافظه کاری بسیار مناسب می‌باشد. در آزمون N-BACK، دنباله‌ای از اعداد، گام به گام به عنوان محرک دیداری به طور تصادفی روی صفحه ظاهر می‌شوند. سپس فرد آزمودنی باید بررسی کند که آیا محرک ارائه شده فعلی با محرک n گام قبل از آن همخوانی دارد یا خیر. در آزمون N-BACK محرک ارائه شده با محرک قبل مقایسه می‌شود (۴۵). این ابزار توانایی پردازش، انتخاب و ذخیره اطلاعات را در مدت زمان بسیار کوتاهی ارزیابی می‌کند. در مجموع ۱۲۰ رقم به مدت پنج دقیقه با فاصله ۱۵۰۰ میلی ثانیه (میلی ثانیه) در مرکز صفحه نمایش داده شد. یک تست n-back می‌تواند شامل ۱ تا N مرحله باشد. به عنوان مثال در یک تست n-back دو مرحله‌ای، در مرحله اول که back-1 نامیده می‌شود، از شرکت کنندگان خواسته شد تا دو رقم متوالی را که روی صفحه ظاهر می‌شوند و بلافاصله مقایسه کنند. اگر دو رقم یکسان بود، دکمه پاسخ را روی یک صفحه کلید خاص فشار دهید. در مرحله دوم (back-2) اگر محرک با محرک دوم قبل از آن یکی باشد، از شرکت کننده خواسته می‌شود که دکمه مورد نظر را فشار دهد. در نهایت زمان واکنش و میانگین پاسخ صحیح به عنوان متغیرهای وابسته در این آزمون ثبت شد.

مدلسازی تغییرات عملکرد شناختی بر اساس الگوریتم

Random Forest و Deep Learning

الگوریتم Deep Learning

ساختار مدل الگوریتمی Deep learning

بسیار عمیق‌تر و پیچیده‌تر از ساختار دو یا سه لایه‌ای الگوریتم‌های قدیمی است. گاهی اوقات تعداد لایه‌های آن می‌تواند بیشتر از صد عدد باشد، که آن را قادر می‌سازد تا حجم زیادی از داده‌ها را در دسته بندی‌های پیچیده پردازش کند. نحوه عملکرد Deep learning بسیار شبیه فرآیند یادگیری در انسان است و دارای فرآیند انتزاعی لایه-لایه است. هر لایه دارای وزن متفاوتی خواهد بود و این وزن نشان دهنده‌ی هر چیزی است که در مورد اجزای تصاویر دوربین‌های مداربسته یاد گرفته شده است. هرچه سطح لایه بالاتر باشد، مولفه‌های آن خاص‌تر خواهد بود. با شبیه‌سازی عملکرد مغز انسان در این تکنولوژی، یک سیگنال اصلی در Deep learning از طریق لایه‌های پردازشی عبور می‌کند؛ سپس، آن را از یک برداشت سطحی (کم عمق) به یک مفهوم (عمیق) تبدیل کرده که قابل درک برای ما خواهد بود (۴۶، ۴۷). Deep learning به مداخله دستی نیاز ندارد، بلکه به یک کامپیوتر برای توسعه عملکردهای خود متکی است. به این ترتیب می‌تواند ویژگی‌های بسیاری از هدف مورد نظر را تشخیص دهد از جمله ویژگی‌های انتزاعی که توصیف آنها دشوار یا غیرممکن است. هر چه کاراکترها و ویژگی‌های سوژه بیشتر باشد، دقیق‌تر مشخص و طبقه بندی خواهد شد (۴۶، ۴۷).

الگوریتم Random Forest

برای درک چگونگی عملکرد جنگل تصادفی، ابتدا باید الگوریتم "درخت تصمیم" (Decision Tree) که بلوک سازنده جنگل تصادفی است را آموخت. انسان‌ها همه روزه از درخت تصمیم برای تصمیم‌گیری‌ها و انتخاب‌های خود استفاده می‌کنند، حتی اگر ندانند آنچه که از آن بهره می‌برند نوعی الگوریتم یادگیری ماشین است. جنگل تصادفی از تجمعی از درختان که هر کدام با استفاده از n نمونه از اطلاعات ورودی که شامل اطلاعات ژنوتیپی و فنوتیپی افراد جمعیت مرجع است، ایجاد می‌شود. مدل در جمعیت مرجع آموزش می‌بیند و بر جمعیت تایید یا کاندید اعمال می‌شود. یکی از n نمونه وارد هر گره از

کد اخلاق

این مطالعه با کد IR.KMU.REC 1398.635 در کمیته اخلاق دانشگاه علوم پزشکی کرمان تایید شد. قبل از شروع اقدامات، توضیحات لازم در مورد این مطالعه به کارگران داده شد و رضایت کتبی آنها برای شرکت در این پژوهش اخذ شد. همچنین به کارگران اطمینان داده شد که اطلاعات شخصی آنها محرمانه خواهد بود.

آنالیز آماری

در این مطالعه برای آنالیز آماری داده‌ها از SPSS V.18 استفاده شد. سپس از روش‌های توصیفی (میانگین، انحراف معیار و فراوانی) برای جمع بندی داده‌ها استفاده شد. فرض نرمال بودن داده‌ها با استفاده از آزمون کولموگروف اسمیرنوف انجام شد. مبنای اصلی تجزیه و تحلیل داده‌ها بر اساس تحلیل واریانس (ANOVA) بود. سطح معنی داری در تجزیه و تحلیل داده‌ها کمتر از ۰/۰۵ در نظر گرفته شد. علاوه بر این، مدل‌سازی تغییرات توجه پایدار و حافظه کاری با استفاده از IBM SPSS Modeler 18.0 انجام شد.

یافته‌ها

۱-۳- اطلاعات دموگرافیک

در جدول ۱ اطلاعات دموگرافیک افراد مورد مطالعه به تفکیک سه گروه بیان شده است. میانگین سنی گروه اول $22/75 \pm 36/23$ و میانگین سنی گروه دوم $31/51 \pm 32/03$ است. سابقه کار گروه سوم $2/3 \pm 7/03$ و سابقه کار کل افراد شرکت‌کننده در مطالعه $2/4 \pm 7/75$ است.

میانگین تراز صدای معادل (SPL_{Leq})

براساس نتایج جدول ۲، گروه کنترل در مواجهه با میانگین تراز صدای معادل $74/30 \pm 1/12$ dB می‌باشد درحالی‌که کارگران گروه مورد به ترتیب در مواجهه با میانگین تراز صدای معادل $80/97 \pm 1/89$ dB و $93/86 \pm 1/69$ dB بودند.

هر درخت می‌شود و از این نمونه اطلاعات یک SNP برای تقسیم بندی مورد استفاده قرار می‌گیرد. این کار در گره‌های متوالی انجام می‌شود تا در نهایت به برگ‌ها و یا همان گره‌های پایانی برسیم که در آن‌ها حداکثر یکنواختی وجود خواهد داشت (۴۸، ۴۹).

سنجش عوامل موثر بر توجه پایدار و حافظه کاری با استفاده از الگوریتم‌های DL و RF

مدل‌سازی مقادیر توجه پایدار و حافظه کاری با ورود تمام داده‌های مربوط به تراز فشار صوت، سن، سابقه کار، سن، متابولیسم و شاخص توده بدنی به IBM SPSS modeler V.18 انجام شد. داده‌ها ابتدا طبقه بندی و سپس با نسبت ۷۰ به ۳۰ (۷۰ درصد از داده‌ها صرف آموزش الگوریتم و ۳۰ درصد برای آزمایش) و بیش از ۲۰۰ بار تکرار شد. در داده کاوی معمولاً از ۷۰ درصد داده‌ها برای آموزش مدل توسعه یافته و ۳۰ درصد از آنها برای آزمایش مدل توسعه یافته استفاده می‌شود. ۲۰۰ تکرار به معنای تعداد تکرار توسط نرم‌افزار (در مرحله داده آموزش) برای یافتن نقطه بهینه مدل در پیش‌بینی و وزن دهی داده‌ها است. تعداد تکرارها به صورت خودکار توسط نرم‌افزار تعیین می‌شود. در نهایت، نسبت تاثیر عوامل به عنوان وزن محاسبه شد.

ارزیابی صحت مدل‌ها

در الگوریتم‌های طبقه بندی که برای دسته بندی متغیر خروجی از نوع گسسته کاربرد دارد، از معیارهای ارزیابی همچون صحت، ماتریس سردرگمی، حساسیت، ویژگی، AUC و غیره استفاده می‌شود. در این پژوهش از دو معیار صحت^۴ (AUC) استفاده شد که هرچه مقدار AUC بیشتر باشد، اعتبار روش بالاتر است. مطابق با معادله ۴، صحت مدل در واقع نسبت موارد درست پیش‌بینی شده به کل موارد است (۵۰).

$$Accuracy = \frac{True\ Positive\ cases + True\ Negative\ cases}{All\ cases} \quad 4$$

6. Accuracy

جدول ۱: اطلاعات دموگرافیک افراد تحت مطالعه

| P-value | متغیر | | | |
|---------|---------------------|------------------|------------------|------------------|
| | کل افراد (n=120) | گروه ۳ (n=40) | گروه ۲ (n=40) | گروه ۱ (n=40) |
| | M(SD) | M(SD) | M(SD) | M(SD) |
| * /0.01 | ۳۳/۴۳±۳/۷۰ | ۲۸/۰۳±۳/۰۱ | ۳۲/۰۳±۳/۵۱ | ۳۶/۲۳±۲/۷۵ |
| * /0.01 | ۲۷/۰۹±۲/۵۰ | ۳۰/۱۲±۱/۴۰ | ۲۷/۸۹±۲/۴۱ | ۲۷/۲۷±۱/۵۵ |
| * /0.01 | ۷/۷۵±۲/۴ | ۷/۰۳±۲/۳۰ | ۷/۰۳±۲/۳۰ | ۹/۱۰±۲/۰۵ |
| * /0.01 | ۱۴۳/۳۶±۳۴/۵۱ | ۱۷۸±۱/۲۵ | ۱۵۴/۴±۱/۳۲ | ۱۱۰/۷±۱/۰۶ |

* P<0.05

جدول ۲: نتایج اندازه‌گیری میانگین تراز صدای معادل در سه گروه مورد مطالعه

| P-value | تراز صدای مواجهه فردی (Leq) | | گروه کارگران | متغیر |
|---------|-----------------------------|------------|--------------|-------------------------|
| | M(SD) | M(SD) | | |
| * /0.01 | ۷۴/۳۰±۱/۱۲ | ۸۰/۹۷±۱/۸۹ | گروه ۱ | میانگین تراز صدای معادل |
| | | ۹۳/۸۶±۱/۶۹ | گروه ۲ | |
| | | | گروه ۳ | |

* P<0.05

جدول ۳: میانگین خطای ارتکابی، خطای حذف و زمان پاسخگویی کارگران هر ۳ گروه در ابتدا، وسط و انتهای شیفت

| متغیر | گروه | ابتدای شیفت | | وسط شیفت | | انتهای شیفت | |
|---------------|---------|-------------|--------------|----------|--------------|-------------|--------------|
| | | میانگین | انحراف معیار | میانگین | انحراف معیار | میانگین | انحراف معیار |
| خطای ارتکابی | گروه ۱ | ۰/۷ | ۰/۱۵ | ۰/۶ | ۰/۰۹ | ۳ | ۰/۲۵ |
| | گروه ۲ | ۱/۲۵ | ۰/۳۲ | ۲ | ۰/۲۱ | ۱/۷۵ | ۰/۳۳ |
| | گروه ۳ | ۱/۸ | ۰/۲۷ | ۳/۲ | ۰/۴۶ | ۳/۹ | ۰/۵۸ |
| | P-Value | ۰/۱۲ | | ۰/۰۵۷ | | ۰/۰۳۲ | |
| خطای حذف | گروه ۱ | ۱/۷ | ۰/۲۶ | ۱/۴ | ۰/۱۷ | ۰/۵ | ۰/۱۲ |
| | گروه ۲ | ۱/۴ | ۰/۱۷ | ۱/۷۵ | ۰/۲۳ | ۱/۵ | ۰/۱۵ |
| | گروه ۳ | ۲ | ۰/۱۵ | ۳/۴ | ۰/۳۲ | ۳/۷۵ | ۰/۳۸ |
| | P-Value | ۰/۴۵ | | ۰/۰۰۲ | | ۰/۰۰۱ | |
| زمان پاسخگویی | گروه ۱ | ۴۲۰ | ۲۲ | ۴۱۵ | ۲۶ | ۴۲۷ | ۱۸ |
| | گروه ۲ | ۴۵۰ | ۱۹ | ۴۳۵ | ۱۲ | ۴۶۵ | ۱۲ |
| | گروه ۳ | ۴۷۰ | ۱۲ | ۴۷۵ | ۳۲ | ۴۹۰ | ۳۷ |
| | P-Value | ۰/۲۵ | | ۰/۰۰۱ | | ۰/۰۰۱ | |

تست توجه پایدار (CPT)

در جدول ۳ میانگین خطای ارتکابی، خطای حذف و زمان پاسخگویی کارگران هر ۳ گروه در ابتدا، وسط و انتهای شیفت نشان داده شده است. مطابق نتایج جدول ۳، در انتهای شیفت خطای ارتکابی به طور معناداری تحت تاثیر قرار گرفته است. همچنین میانگین تراز صدای معادل بر خطای حذف در وسط و انتهای شیفت از نظر

اماری دارای اختلاف معناداری بود. علاوه بر این، میانگین تراز صدای معادل بر زمان پاسخگویی کارگران در وسط و انتهای شیفت به طور معناداری تاثیر گذاشت.

تست حافظه کاری (N-back)

در جدول ۴ نتایج زمان واکنش و میانگین پاسخ صحیح در ابتدا، وسط و انتهای شیفت نشان داده شده

جدول ۴: میانگین زمان واکنش و میانگین پاسخ صحیح در هر سه گروه مورد مطالعه در ابتدا، وسط و انتهای شیفت

| متغیر | گروه | ابتدای شیفت | | وسط شیفت | | انتهای شیفت | |
|------------|---------|-------------|--------------|----------|--------------|-------------|--------------|
| | | میانگین | انحراف معیار | میانگین | انحراف معیار | میانگین | انحراف معیار |
| زمان واکنش | گروه ۱ | ۵۴۰ | ۱۵ | ۵۸۰ | ۲۹ | ۶۰۵ | ۲۷ |
| | گروه ۲ | ۵۵۵ | ۳۴ | ۵۸۵ | ۳۲ | ۶۲۷ | ۳۸ |
| | گروه ۳ | ۵۷۰ | ۳۷ | ۶۰۰ | ۴۱ | ۶۴۰ | ۵۲ |
| | P-Value | ۰/۳۸ | | ۰/۰۳۵ | | ۰/۰۰۱ | |
| پاسخ صحیح | گروه ۱ | ۸۰ | ۱۱ | ۸۹ | ۱۰ | ۷۹ | ۹ |
| | گروه ۲ | ۷۸ | ۴ | ۷۰ | ۱۵ | ۶۴ | ۱۲ |
| | گروه ۳ | ۷۵ | ۶ | ۶۸ | ۹ | ۵۸ | ۷ |
| | P-Value | ۰/۴۵ | | ۰/۰۰۱ | | ۰/۰۰۱ | |

جدول ۴: نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای خطای حذف

| متغیر | ابتدای شیفت | | وسط شیفت | | انتهای شیفت | |
|----------------------------------|----------------------|-------|----------------------|-------|----------------------|-------|
| | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | |
| | DL | RF | DL | RF | DL | RF |
| وزن تراز صدای معادل (L_{eq}) | ۳۵/۹ | ۳۲/۴۷ | ۳۱/۵۱ | ۳۱/۷۴ | ۴۵/۴۶ | ۴۴/۳۷ |
| وزن سابقه کار | ۲۳/۰۸ | ۲۲/۲۵ | ۱۲/۳۳ | ۱۱/۸۱ | ۱۴/۵۵ | ۱۵/۱۲ |
| وزن سن | ۲۰/۵ | ۱۹/۹۲ | ۱۲/۳۳ | ۱۳/۲۳ | ۱۲/۷۱ | ۱۱/۹۱ |
| وزن وزن متابولیسم | ۱۰/۲۶ | ۱۴/۳ | ۲۳/۲۸ | ۲۰/۷۵ | ۱۴/۵۵ | ۱۳/۱۱ |
| وزن شاخص توده بدنی | ۱۰/۲۶ | ۱۱/۰۶ | ۲۰/۵۵ | ۲۲/۴۷ | ۱۲/۷۳ | ۱۵/۴۹ |
| دقت مدل | ٪۹۴ | ٪۹۳ | ٪۹۱ | ٪۸۷ | ٪۹۰ | ٪۹۱ |

است که بر اساس آن مشخص شد که میانگین تراز صدای معادل بر زمان واکنش و پاسخ صحیح کارگران در وسط و انتهای شیفت به طور معناداری تاثیر می گذارد.

است. همچنین نتایج مدلسازی الگوریتم Deep Learning نشان داد که وزن L_{eq} در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۳۲/۴۷، ۳۱/۷۴ و ۴۴/۳۷ می باشد.

مدلسازی خطای ارتکاب

نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای خطای ارتکاب در جدول ۵ نشان داده شده است. وزن متغیر L_{eq} طبق نتایج حاصل از الگوریتم Random Forest برای اول شیفت، وسط شیفت و آخر شیفت به ترتیب برابر ۳۳/۳۴، ۳۸/۰۹ و ۳۳/۳۳ است. همچنین الگوریتم Deep Learning

مدلسازی عوامل با الگوریتم های Deep Learning و Random Forest مدلسازی خطای حذف نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای خطای حذف در جدول ۴ نشان داده شده است. طبق نتایج حاصل از مدلسازی با الگوریتم Random Forest وزن L_{eq} در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۳۵/۹، ۳۱/۵۱ و

مدلسازی عوامل با الگوریتم های Deep Learning و Random Forest

مدلسازی خطای حذف

نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای خطای حذف در جدول ۴ نشان داده شده است. طبق نتایج حاصل از مدلسازی با الگوریتم Random Forest وزن L_{eq} در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۳۵/۹، ۳۱/۵۱ و

جدول ۵: نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای خطای ارتکاب

| انتهای شیفت | | وسط شیفت | | ابتدای شیفت | | متغیر |
|----------------------|-------|----------------------|-------|----------------------|-------|----------------------------------|
| نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | |
| DL | RF | DL | RF | DL | RF | |
| ۳۴/۱۲ | ۳۳/۳۳ | ۳۵/۶۷ | ۳۸/۰۹ | ۳۲/۵ | ۳۳/۳۴ | وزن تراز صدای معادل (L_{eq}) |
| ۱۸/۷۵ | ۱۹/۰۵ | ۸/۲۳ | ۷/۱۴ | ۲۶/۲۵ | ۲۵ | وزن سابقه کار |
| ۱۳/۹۸ | ۱۴/۲۹ | ۱۴/۷۶ | ۱۵/۴۸ | ۱۳/۵ | ۱۲/۵ | وزن سن |
| ۱۵/۴۵ | ۱۶/۶۷ | ۲۶/۳۲ | ۲۵ | ۱۱/۷۵ | ۱۲/۵ | وزن وزن متابولیسم |
| ۱۷/۷ | ۱۶/۶۶ | ۱۵/۰۲ | ۱۴/۲۹ | ۱۶ | ۱۶/۶۶ | وزن شاخص توده بدنی |
| %۹۲ | %۸۷ | %۹۰ | %۸۷ | %۹۷ | %۸۸ | دقت مدل |

جدول ۶: نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای زمان پاسخ

| انتهای شیفت | | وسط شیفت | | ابتدای شیفت | | متغیر |
|----------------------|-------|----------------------|-------|----------------------|-------|----------------------------------|
| نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | |
| DL | RF | DL | RF | DL | RF | |
| ۲۸/۷۵ | ۲۹/۹۹ | ۲۵ | ۲۴/۹۹ | ۴۶/۷۸ | ۴۷/۲۲ | وزن تراز صدای معادل (L_{eq}) |
| ۸/۵ | ۹/۹۹ | ۲/۱ | ۲/۰۹ | ۷/۹۲ | ۸/۳۳ | وزن سابقه کار |
| ۲۷/۲۵ | ۲۶/۶۸ | ۳۹/۶ | ۳۹/۵۸ | ۲۴/۵۳ | ۲۵ | وزن سن |
| ۵ | ۳/۳۵ | ۱۴/۵ | ۱۴/۵۸ | ۱۰/۷۷ | ۱۱/۱۱ | وزن وزن متابولیسم |
| ۳۱/۵ | ۲۹/۹۹ | ۱۸/۸۰ | ۱۸/۷۶ | ۹ | ۸/۳۴ | وزن شاخص توده بدنی |
| %۸۹ | %۹۱ | %۹۵ | %۹۱ | %۸۹ | %۹۶ | دقت مدل |

شیفت و آخر شیفت به ترتیب برابر ۴۷/۲۲، ۲۴/۹۹ و ۲۹/۹۹ است. همچنین الگوریتم Deep Learning نشاد داد که وزن متغیر L_{eq} برای اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۴۶/۷۸، ۲۵ و ۲۸/۷۵ بود.

مدلسازی زمان واکنش

نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای زمان واکنش در جدول ۷ نشان داده شده است. طبق نتایج حاصل از مدلسازی با الگوریتم

نشاد داد که وزن متغیر L_{eq} برای اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۳۲/۵، ۳۵/۶۷ و ۳۴/۱۲ بود.

مدلسازی زمان پاسخ

نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای زمان پاسخ در جدول ۶ نشان داده شده است. وزن متغیر L_{eq} طبق نتایج حاصل از الگوریتم Random Forest برای اول شیفت، وسط

جدول ۷: نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای زمان واکنش

| انتهای شیفت | | وسط شیفت | | ابتدای شیفت | | متغیر |
|----------------------|-------|----------------------|-------|----------------------|-------|----------------------------------|
| نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | |
| DL | RF | DL | RF | DL | RF | |
| ۳۸/۵۰ | ۳۹/۹۹ | ۴۵ | ۴۴/۴۴ | ۴۲/۵۰ | ۴۳/۶۴ | وزن تراز صدای معادل (L_{eq}) |
| ۱۰/۲۵ | ۹/۹۹ | ۱۰/۵۰ | ۱۱/۱۱ | ۲۲/۳۰ | ۲۱/۸۱ | وزن سابقه کار |
| ۱۴ | ۱۳/۳۵ | ۱۱/۷۵ | ۱۱/۱۲ | ۱۳/۷۵ | ۱۴/۵۵ | وزن سن |
| ۷/۲۵ | ۶/۶۸ | ۸/۲۵ | ۷/۴۱ | ۸/۸۵ | ۹/۱ | وزن وزن متابولیسم |
| ۳۰ | ۲۹/۹۹ | ۲۴/۵۰ | ۲۵/۹۲ | ۱۲/۶۰ | ۱۰/۹ | وزن شاخص توده بدنی |
| %۸۹ | %۹۱ | %۹۲ | %۹۶ | %۹۳ | %۹۹ | دقت مدل |

جدول ۸: نتایج مدلسازی الگوریتم های Deep Learning و Random Forest برای پاسخ صحیح

| انتهای شیفت | | وسط شیفت | | ابتدای شیفت | | متغیر |
|----------------------|-------|----------------------|-------|----------------------|-------|----------------------------------|
| نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | نوع الگوریتم مدلسازی | | |
| DL | RF | DL | RF | DL | RF | |
| ۲۶/۵۰ | ۲۶/۸۶ | ۲۶/۵۰ | ۲۷/۳۹ | ۱۷ | ۱۶/۲۷ | وزن تراز صدای معادل (L_{eq}) |
| ۲۲ | ۲۲/۳۹ | ۲۲/۵۰ | ۲۱/۹۳ | ۲۸/۵۰ | ۲۷/۹ | وزن سابقه کار |
| ۷/۷۵ | ۷/۴۶ | ۱۰ | ۹/۵۹ | ۱۲/۰۳ | ۱۱/۶۲ | وزن سن |
| ۱۸ | ۱۷/۹۲ | ۱۸/۷۵ | ۱۹/۱۸ | ۱۷/۹۷ | ۱۸/۶ | وزن وزن متابولیسم |
| ۲۵/۷۵ | ۲۵/۳۷ | ۲۲/۲۵ | ۲۱/۹۱ | ۲۴/۵۰ | ۲۵/۵۸ | وزن شاخص توده بدنی |
| %۸۹ | %۹۱ | %۹۵ | %۹۶ | %۹۳ | %۹۹ | دقت مدل |

الگوریتم Random Forest وزن شاخص توده بدنی در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۲۵/۵۸، ۲۱/۹۱ و ۲۵/۳۷ است. همچنین نتایج مدلسازی الگوریتم Deep Learning نشان داد که وزن شاخص توده بدنی در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۲۴/۵۰، ۲۲/۲۵ و ۲۵/۷۵ می باشد.

بحث

در این مطالعه، تغییرات توجه پایدار متمرکز و پاسخهای فیزیولوژیک کارگران مواجهه یافته با ترازهای مختلف فشار

Random Forest وزن L_{eq} در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۴۳/۶۴، ۴۴/۴۴ و ۳۹/۹۹ است. همچنین نتایج مدلسازی الگوریتم Deep Learning نشان داد که وزن L_{eq} در اول شیفت، وسط شیفت و آخر شیفت به ترتیب ۴۵، ۴۲/۵۰ و ۳۸/۵۰ می باشد.

مدلسازی پاسخ صحیح

نتایج مدلسازی الگوریتمهای Deep Learning و Random Forest برای پاسخ صحیح در جدول ۸ نشان داده شده است. طبق نتایج حاصل از مدلسازی با

صوت با استفاده از الگوریتم‌های Deep Learning و Random Forest در ابتدا، وسط و انتهای شیفت مدلسازی شد. نتایج آزمون عملکرد پیوسته نشان داد که خطای حذف، خطای ارتکابی و زمان پاسخگویی هر سه گروه تحت تأثیر زمان شیفت قرار می‌گیرند، هر سه مولفه به طور معنی داری در انتهای شیفت افزایش یافتند، به عبارتی عملکرد شناختی افراد کاهش یافت. جداول ۴ الی ۸ نتایج مدلسازی تغییرات توجه پایدار متمرکز و پاسخ‌های فیزیولوژیک کارگران مواجهه یافته با ترازهای مختلف فشار صوت را نشان می‌دهند. وزن هر کدام از متغیرهای Leq، سن، سابقه کار، BMI و متابولیسم برای هر یک از آزمون‌های CPT و N-Back در اول شیفت، وسط و آخر شیفت محاسبه شده است.

همسو با این مطالعه ماکی و همکارانش نیز در مطالعات آزمایشگاهی و میدانی کاهش عملکرد شناختی و اختلال در پردازش اطلاعات را در انتهای شیفت گزارش کرده‌اند (۵۱). اما خطای ارتکابی و خطای حذف به طور معنی داری تحت تأثیر صدا قرار نگرفتند ($P > 0.05$). به طور کلی بیشترین خطای ارتکابی و خطای حذف مربوط به گروه ۳ می‌باشد که با میانگین تراز صدای معادل $93/86 \pm 1/69$ dB مواجهه داشتند در صورتیکه این سه مولفه در گروه کنترل و گروه ۲، کمترین مقدار را به خود اختصاص داده‌اند که در تناقض با مطالعه بلوویویچ و همکاران در سال ۲۰۰۱ بود. آنان با هدف بررسی قدرت محاسباتی ریاضی ۱۲۳ دانشجو تحت شرایط بدون صدا و صدای ترافیک ضبط شده و ارتباط آن با تیپ شخصیتی افراد، به این نتیجه رسیدند که در افراد برون‌گرا پخش صدا باعث بهبود قدرت محاسباتی می‌شود (۵۲) اما در توافق با نتایج تحقیقات به و کارتر در سال ۱۹۸۷ بود که به منظور بررسی اثر صدا بر عملکرد ذهنی یافتند صدا در ترازهای کمتر از ۷۰ dBA قادر است عملکرد را بهبود ببخشد ولی می‌تواند در ترازهای بالاتر از ۹۰ dBA اثر منفی بر عملکرد داشته باشد (۵۳).

در بررسی عملکرد حافظه کاری (n-back) صحت و سرعت پردازش اطلاعات به‌عنوان دو متغیر مورد ارزیابی

قرار گرفت. صحت، با استفاده از میانگین پاسخ‌های صحیح و سرعت، با استفاده از میانگین زمان واکنش به دست آمد. در وظیفه حافظه کاری (n-back) مشخص شد که ترازهای فشار صوت مختلف بر زمان واکنش کارگران به طور معنی داری تأثیر می‌گذارند و همچنین زمان واکنش در گروه ۲ و ۳ بعد از مواجهه با ترازهای فشار صوت به صورت معنی داری افزایش می‌یابد ($P < 0.05$). در همین راستا در سال ۲۰۱۵ ایرگنس-هانسن و همکارانش عملکرد شناختی نیروهای دریایی نروژ را در مواجهه با ترازهای فشار صوت مورد مطالعه قرار دادند که زمان واکنش آنها در مواجهه با ترازهای فشار صوت بالا به طور معنی داری افزایش یافت (۵۴) و همچنین در مطالعه‌ای که هانکوک در سال ۲۰۱۱ با هدف بررسی اثرات صدا بر عملکرد انسان انجام داد مشخص شد که صدا تأثیر منفی بر دقت و زمان واکنش دارد (۵۵) و نتایج مطالعه‌ای دیگر که ذکایی و همکارانش با هدف بررسی اختلال عملکرد شناختی در مواجهه با صدای ترافیکی انجام دادند و به این نتیجه رسیدند که زمان عکس العمل بعد از مواجهه با صدا به صورت معناداری افزایش می‌یابد (۵۶) به نتایج مطالعه ما بسیار نزدیک است، اما پیر در سال ۲۰۰۹ در مطالعه‌ای برای تعیین اثر صدا و فشار زمانی بر روی عملکرد، سطح انگیزتگی و بار کاری ذهنی، زمانی که افراد آزمون استروپ و پردازش معنایی را انجام دادند به این نتیجه رسید که صدای متناوب تأثیری بر زمان واکنش افراد ندارد و باعث افزایش زمان واکنش نمی‌شود (۵۷) و نتیجه‌ای مشابه در مطالعه‌ای که علیمحمدی و همکارانش در سال ۱۳۹۴ با هدف بررسی تأثیر صدای ترافیک بر عملکرد شناختی رانندگان انجام دادند و نشان دادند که صدای ترافیک در متغیرهای درک محیطی و زمان واکنش انتخابی شرکت کنندگان تأثیرگذار نیست، گرفته شد (۵۸) که با نتایج مطالعه حاضر در تناقض بود. در مطالعه‌ای که توسط Noma و همکاران در سال ۲۰۱۳ با هدف پیش‌بینی علائم افت شنوایی با استفاده از داده‌های ادیومتری و با روش‌های الگوریتم FP-Growth انجام شد، در ۵ مدل مختلف نرخ خطا به ترتیب ۰، ۰/۵،

مدل‌های حاصل از الگوریتم Deep Learning بالا و قابل قبول است. در مطالعه Nawi و همکاران در سال ۲۰۱۱ با استفاده از الگوریتم Gradient Descent With Adaptive Momentum (GDAM) و در نظر گرفتن متغیرهای سن، سابقه کار و میزان مواجهه کارگران به عنوان فاکتورهای اصلی درگیر در افت شنوایی، به پیش‌بینی NIHIL پرداختند. صحت به دست آمده در پیش‌بینی افت شنوایی کارگران را برای گوش چپ ۹۹/۳۷٪ و برای گوش راست ۹۹/۰۱٪ به دست آورد (۵۱) که این مقدار صحت به مطالعه ما نزدیک است به گونه‌ای که صحت بیشتر مدل‌های به دست آمده بالای ۹۰ درصد محاسبه گردید.

مزیت مطالعه حاضر استفاده از الگوریتم‌های داده کاوی برای طبقه بندی و وزن دهی تأثیر عوامل مؤثر بر نتایج آزمون‌های N-BACK و CPT است. استفاده از چنین الگوریتم‌هایی دقت مطالعه را در مقایسه با روش‌های آماری مرسوم افزایش می‌دهد. مهم‌ترین محدودیت پژوهش حاضر را می‌توان طراحی مقطعی آن، عدم همکاری کارکنان به دلیل تداخل در وظایف روزمره آنها دانست. پیشنهاد می‌شود در مطالعات آتی تحقیقات به صورت طولی و با مشارکت بیشتر و در مشاغل مختلف انجام شود.

نتیجه گیری

نتایج این پژوهش نشان داد که با توجه به وزن بالای به دست آمده از صدا در مدلسازی‌های آزمون‌ها، در سه زمان ابتدا، وسط و انتهای شیفت بر مولفه‌های عملکرد پیوسته (CPT) و عملکرد حافظه کاری (n-back) از جمله زمان پاسخگویی و زمان واکنش کارگران اثر می‌گذارد و در طول شیفت میزان خطای کارگران افزایش و دقت آنها کاهش می‌یابد. از طرفی به دلایل حساسیت بالای شغلی کارگران صنعت فولاد، تعداد نیرو، مواجهه با انواع عوامل زیان‌آور و همچنین شرایط محیطی سخت اختلال در عملکرد شناختی آنان می‌تواند از نظر ایمنی بسیار خطرناک باشد و باید به راهکارهای کنترلی بیش از گذشته اهمیت داده شود. لذا مطالعه حاضر می‌تواند توسط مدیران ایمنی و

۱، ۱/۷۵ و ۵/۴ درصد با تکرار بالای ۱۰ بار به دست آمد (۴۸)، در مطالعه حاضر نیز نرخ خطاهای مدلسازی تغییرات توجه پایدار ناچیز به دست آمد. بنابراین ارتباط خوبی بین متغیرهای تاثیرگذار در توجه پایدار کارگران به دست آمد. در مطالعه Elbasi و همکارش (۲۰۱۲) نیز که با هدف پیش‌بینی افت‌های شنوایی (به ترتیب نوع انتقالی، حسی-عصبی، ترکیبی و نرمال) بر اساس ادیومتری با استفاده از الگوریتم‌های داده کاوی J48، Naïve Bayes، Neural Network، انجام شد، نتایج به این صورت بود که در استفاده از الگوریتم J48 نرخ خطا برای مدلسازی افت‌های شنوایی به ترتیب ۰/۰۱۴، ۰/۰۰۷، ۰/۰۳۶ و ۰/۰۰۶ به دست آمد. در روش Naïve Bayes نرخ خطا برای مدلسازی افت‌های شنوایی به ترتیب ۰/۰۱۴، ۰/۰۶۴، ۰/۱۱۴ و ۰ به دست آمد. در الگوریتم Neural Network نرخ خطا برای مدلسازی افت‌های شنوایی به ترتیب ۰/۰۱۴، ۰/۰۳۶، ۰/۰۴۳ و ۰ به دست آمد. در نهایت صحت کلی روش‌های Naïve، J48، Neural Network و Bayes جهت مدلسازی افت شنوایی به ترتیب ۰/۹۵/۵، ۰/۸۶/۵ و ۰/۹۳/۵ به دست آمد (۴۹). نرخ خطا در مطالعه Elbasi نسبتاً بالا بوده است؛ در مطالعه حاضر مدلسازی‌ها از نرخ خطا قابل قبولی برخوردار بودند. در مطالعه Majumder و همکارش (۲۰۱۴) که با هدف کاربرد تکنیک‌های داده کاوی بدون نظارت شامل: Expectation Maximization (EM)، Linear Vector، K-means، Self Organization، Quantization (LVQ)، Map (SOM) و تکنیک‌های داده کاوی با نظارت شامل: Naïve Bayes، Instance-based (IB)، Radial، Back Propagation Network (BPN) (RBF) جهت مدلسازی تغییرات افت شنوایی با استفاده از داده‌های ادیومتری در رانندگان حرفه‌ای انجام شد نیز همانند مطالعه حاضر به این نتیجه رسیدند که تمام الگوریتم‌های داده کاوی به جز الگوریتم RBF برای گوش راست، سازگاری و عملکرد نسبتاً بالایی را نشان می‌دهند، (۵۰). در مطالعه حاضر نیز صحت

۹۸۰۰۱۰۳۰) است که در پژوهشکده آینده پژوهی در سلامت دانشگاه علوم پزشکی کرمان به تصویب رسیده است. بدین ترتیب از حمایت‌ها و مشارکت معاونت پژوهشی دانشگاه و نیز مسئولین محترم صنعت فولاد و کارکنانی که در این مطالعه به ما کمک کردند، تشکر می‌نماییم.

بهداشت برای اجرای راهبردی موثر و بهبود عملکردهای شناختی گروه‌های مختلف کارگران در حین انجام وظیفه، مورد استفاده قرار گیرد.

تشکر و قدردانی

این مطالعه حاصل طرح پژوهشی به شماره

REFERENCES

1. Esmaeili R, Zare S, Ghasemian F, Pourtaghi F, Saeidnia H, Pourtaghi G. Predicting and classifying hearing loss in sailors working on speed vessels using neural networks: a field study. *Med Lav*. 2022;113(3)
2. Dobie RA. The burdens of age-related and occupational noise-induced hearing loss in the United States. *Ear Hear*. 2008;29(4):565-77.
3. Concha-Barrientos M, Steenland K, Prüss-Üstün A, Campbell-Lendrum DH, Corvalán CF, Woodward A, et al. Occupational noise: assessing the burden of disease from work-related hearing impairment at national and local levels: World Health Organization; 2004.
4. Zare S, Hasheminezhad N, Sarebanzadeh K, Zolala F, Hemmatjo R, Hassanvand D. Assessing thermal comfort in tourist attractions through objective and subjective procedures based on ISO 7730 standard: A field study. *Urban Clim*. 2018;26:1-9.
5. Kazemi R, Zare S, Hemmatjo R. Comparison of melatonin profile and alertness of firefighters with different work schedules. *J Circadian Rhythms*. 2018;16.
6. Zamanian Z, Kakooei H, Ayattollahi S, Dehghani M. Effect of bright light on shift work nurses in hospitals. *Pak J Biol Sci*. 2010;13(9):431-6.
7. Rostamabadi A, Zamanian Z, Sedaghat Z. Factors associated with work ability index (WAI) among intensive care units (ICUs) nurses. *J Occup Health*. 2017;16-0060-OA.
8. Alimohamadi I, Soltani R, Azkhosh M, Gohari M, Moosavi B. Study of role extroversion of caused by traffic noise on mental function of the students. *Iran Occup Health*. 2011;7(4):7-0.
9. Rahmani R, Aliabadi M, Golmohammadi R, Babamiri M, Farhadian M. Body physiological responses of city bus drivers subjected to noise and vibration exposure in working environment. *Heliyon*. 2022;8(8).
10. Bar-Tal Y, Shrira A, Keinan G. The effect of stress on cognitive structuring: A cognitive motivational model. *Pers Soc Psychol Rev*. 2013;17(1):87-99.
11. Rahmani R, Aliabadi M, Golmohammadi R, Babamiri M, Farhadian M. Evaluation of cognitive performance of City bus drivers with respect to noise and vibration exposure. *Acoust Aust*. 2021;49(3):529-39.
12. Hygge S. Classroom experiments on the effects of different noise sources and sound levels on long-term recall and recognition in children. *Appl Cogn Psychol*. 2003;17(8):895-914.
13. Cui B, Wu M, She X. Effects of chronic noise exposure on spatial learning and memory of rats in relation to neurotransmitters and NMDAR2B alteration in the hippocampus. *J Occup Health*. 2009;0902160059-.
14. Lowden A, Kecklund G, Axelsson J, Åkerstedt T. Change from an 8-hour shift to a 12-hour shift, attitudes, sleep, sleepiness and performance. *Scand J Work Environ Health*. 1998:69-75.
15. Hahad O, Bayo Jimenez MT, Kuntic M, Frenis K, Steven S, Daiber A, et al. Cerebral consequences of environmental noise exposure. *Environ Int*. 2022;165:107306.
16. Arjunan A, Rajan R. Noise and brain. *Physiol Behav*. 2020;227:113136.
17. Gawron VJ. Performance effects of noise intensity, psychological set, and task type and complexity. *Hum Factors*. 1982;24(2):225-43.
18. Chraif M. The effects of radio noise in multiple time reaction tasks for young students. *Procedia-Soc Behav Sci*. 2012;33:1057-62.
19. Zare S, Ghotbi-Ravandi MR, ElahiShirvan H, Ahsae MG, Rostami M. Predicting and weighting the factors affecting workers' hearing loss based on audiometric data using C5 algorithm. *Ann Glob Health*. 2019;85(1).

20. Sim CS, Sung JH, Cheon SH, Lee JM, Lee JW, Lee J. The effects of different noise types on heart rate variability in men. *Yonsei Med J.* 2015;56(1):235.
21. Landström U, Åkerlund E, Kjellberg A, Tesarz M. Exposure levels, tonal components, and noise annoyance in working environments. *Environ Int.* 1995;21(3):265-75.
22. Ishiyama T, Hashimoto T. The impact of sound quality on annoyance caused by road traffic noise: an influence of frequency spectra on annoyance. *JSAE Rev.* 2000;21(2):225-30.
23. Smith A. Noise, performance efficiency and safety. *Int Arch Occup Environ Health.* 1990;62(1):1-5
24. Stansfeld SA, Matheson MP. Noise pollution: non-auditory effects on health. *Br Med Bull.* 2003;68(1):243-57.
25. Leventhall G, Pelmear P, Benton S. A review of published research on low frequency noise and its effects. 2003.
26. Heidari H. Applying data mining technique in order to categorize the target users of the Central Library of Isfahan University of Technology (Studying the motives and information seeking behaviors of them). *Iran J Inf Process Manag.* 2017;33(1):271-94.
27. Han J, Kamber M, Pei J. Data mining concepts and techniques third edition. Morgan Kaufmann Ser Data Manag Syst. 2011;5(4):83-124.
28. Bakar AA, Othman Z, Ismail R, Zakari Z, editors. Using rough set theory for mining the level of hearing loss diagnosis knowledge. 2009 International Conference on Electrical Engineering and Informatics; 2009: IEEE.
29. Montes-Jovellar L, Guillen-Grima F, Perez-Fernandez N. Cluster analysis of auditory and vestibular test results in definite Menière's disease. *Laryngoscope.* 2011;121(8):1810-7.
30. Farhadian M, Aliabadi M, Darvishi E. Empirical estimation of the grades of hearing impairment among industrial workers based on new artificial neural networks and classical regression methods. *Indian J Occup Environ Med.* 2015;19(2):84.
31. Noma N, Khanapi M, Ghani A, Mohamad Khir A, Noorizan Y. Predicting hearing loss symptoms from Audiometry data using FP-Growth Algorithm and Bayesian Classifier. *Aust J Basic Appl Sci.* 2013;7(9):35-43.
32. Acir N, Özdamar Ö, Güzeliş C. Automatic classification of auditory brainstem responses using SVM-based feature selection algorithm for threshold detection. *Eng Appl Artif Intell.* 2006;19(2):209-18.
33. Howard J, editor The business impact of deep learning. Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining; 2013.
34. Panetta K. The top 10 strategic technology trends for 2018. Gartner's special report. 2017.
35. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biol.* 1990;52(1-2):99-115.
36. Chen H, Engkvist O, Wang Y, Olivecrona M, Blaschke T. The rise of deep learning in drug discovery. *Drug Discov Today.* 2018;23(6):1241-50.
37. Ramos-Miguel A, Perez-Zaballos T, Perez D, Falcon JC, Ramos A. Use of data mining to predict significant factors and benefits of bilateral cochlear implantation. *Eur Arch Otorhinolaryngol.* 2015;272(11):3157-62.
38. Nawi NM, Rehman M, Ghazali M. Noise-induced hearing loss prediction in Malaysian industrial workers using gradient descent with adaptive momentum algorithm. *Int Rev Comput Softw.* 2011;6(5):740-8.
39. Majumder J, Sharma L. Application of data mining techniques to audiometric data among professionals in India. *J Sci Res Rep.* 2014:2960-71.
40. ISO. 9612: Acoustics-Determination of Occupational Noise Exposure-Engineering Method. Geneva, Switzerland: International Organization for Standardization. 2009.
41. Hojati M, Golmohammadi R, Aliabadi M. Determining the Noise Exposure Pattern in a Steel Company. *J Occup Hyg Eng.* 2016;2(4):1-8.
42. Golmohammadi R. Noise and vibration engineering. 3rd ed. Hamedan: Daneshjoo; 2007.
43. ISO 8996 / EN28996. Ergonomics – Determination of Metabolic Heat Production. International Standardisation Organisation.
44. Jafari MJ, Naserpour M, Monazzam MR, Saremi M, Pouragha Shahheshin HR, Jam Bar Sang S. Evaluation of students' cognitive performance while exposed to heat using continuous performance test. *J Occup Hyg Eng.* 2014;1(2):1-9.
45. Taghizade T, Nejati V, Mohammadzade A, Akbarzade Baghban A. Evolution of auditory and visual working

- memory in primary school-aged children. 2014.
46. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*. 1986;323(6088):533-6.
47. Bartunov S, Santoro A, Richards B, Marris L, Hinton GE, Lillicrap T. Assessing the scalability of biologically-motivated deep learning algorithms and architectures. *Adv Neural Inf Process Syst*. 2018;31.
48. Livingston F. Implementation of Breiman's random forest machine learning algorithm. *ECE591Q Mach Learn J Pap*. 2005;1:13.
49. Wu Q, Ye Y, Zhang H, Ng MK, Ho S-S. ForesTexter: An efficient random forest algorithm for imbalanced text categorization. *Knowl Based Syst*. 2014;67:105-16.
50. Larose DT, Larose CD. *Discovering knowledge in data: an introduction to data mining*: John Wiley & Sons; 2014.
51. Machi MS, Staum M, Callaway CW, Moore C, Jeong K, Suyama J, et al. The relationship between shift work, sleep, and cognition in career emergency physicians. *Acad Emerg Med*. 2012;19(1):85-91.
52. Belojevic G, Slepcevic V, Jakovljevic B. Mental performance in noise: The role of introversion. *J Environ Psychol*. 2001;21(2):209-13.
53. Carter NL, Beh HC. The effect of intermittent noise on vigilance performance. *J Acoust Soc Am*. 1987;82(4):1334-41.
54. Irgens-Hansen K, Gundersen H, Sunde E, Baste V, Harris A, Bråtveit M, et al. Noise exposure and cognitive performance: a study on personnel on board Royal Norwegian Navy vessels. *Noise Health*. 2015;17(78):320.
55. Szalma JL, Hancock PA. Noise effects on human performance: a meta-analytic synthesis. *Psychol Bull*. 2011;137(4):682.
56. Zokaei M, Ali MI, Abareshi F, Flahati M, Faghieh NTY, Khajevandi AA. Study of cognitive dysfunction in exposure to traffic noise. 2017.
57. Pierre MS. *The effects of noise and time pressure on cognitive performance*: Northern Kentucky University; 2009.
58. Alimohammadi I, Mehri A, Sadat S, Akbarzadeh A, Hajizadeh R. The effects of traffic noise on drivers' cognitive performance. *Iran Occup Health*. 2015;12(2).