

Identificador de condutor de veículo utilizando Redes Neurais Artificiais e OBDII

Alternative title: Vehicle driver identifier using Artificial Neural Networks and OBDII

Celso de Ávila Ramos
Departamento de Ciência da
Computação
Universidade José do Rosário Vellano
- UNIFENAS
Alfenas, Brasil
celsodeavila@gmail.com

Wiliam Soares Lacerda
Departamento de Ciência da
Computação
Universidade Federal de Lavras
Lavras, Brasil
lacerda@dcc.ufla.br

Heitor Scalco Neto
Departamento de Ciência da
Computação
Universidade Federal de Lavras
Lavras, Brasil
heiterscalco@hotmail.com

RESUMO

Este artigo descreve o desenvolvimento de uma Rede Neural Artificial para classificação de condutores de veículos, visando determinar a autenticidade de condutores autorizados. Os dados de entrada para a rede neural foram obtidos por meio do dispositivo denominado On Board Diagnostic (OBD), comumente empregado para detectar defeitos em mecanismos do veículo, visando sua manutenção. O sistema desenvolvido procurou dar uma funcionalidade diferenciada para este dispositivo, no auxílio a proprietários de veículos no que diz respeito à segurança de seu patrimônio. Foi utilizado uma rede tipo PMC (Perceptron Multicamadas) com o algoritmo *backpropagation* para treinamento utilizando os dados provenientes de um OBD. Amostras do comportamento de três condutores diferentes foram utilizadas, obtendo as variáveis: posição do acelerador, aceleração em x, aceleração em y e aceleração em z como entradas. Foram utilizadas duas camadas ocultas, com dez neurônios em cada uma. Também foi empregado o cálculo de média móvel para a filtragem dos dados. Os resultados mostraram-se satisfatórios, uma vez que o erro médio quadrático durante o treinamento aproximou-se muito de zero, fazendo com que a rede neural apresentasse um número significativo de acertos durante os testes.

Palavras-Chave

Redes Neurais Artificiais, OBD, classificação.

ABSTRACT

This paper describes the development of an Artificial Neural Network for the classification of vehicle drivers, in order to determine the authenticity of authorized drivers.

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

SBSI 2017, June 5th–8th, 2017, Lavras, Minas Gerais, Brazil.
Copyright SBC 2017.

The input data for the neural network were obtained through the device called On Board Diagnostic (OBD), commonly used to

detect defects in vehicle mechanisms for maintenance purposes. The system developed sought to provide a differentiated functionality for this device, in the aid of vehicle owners with regard to the safety of their assets. A MLP (Multi-layered Perceptron) network was used with the backpropagation algorithm for training using data from an OBD. Behavior samples of three different conductors were used, obtaining the variables: accelerator position, acceleration in x, acceleration in y and acceleration in z as inputs. Two hidden layers were used, with ten neurons in each. We also used the moving average calculation for data filtering. The results were satisfactory, since the mean squared error during the training was very close to zero, causing the neural network to present a significant number of correct answers during the tests.

CCS Concepts

• Computing methodologies → Artificial Intelligence → Planning and Scheduling

Keywords

Artificial Neural Networks, OBD, classification.

1. INTRODUÇÃO

Atualmente, a preocupação com a segurança de bens tem sido uma constante na população, principalmente em países onde os índices de furtos, em diversas dimensões, são elevados. Diante de um cenário preocupante, questões sobre como desenvolver tecnologias e soluções que consigam reduzir os índices de furtos devem ser abordadas, buscando aprimorar técnicas existentes e ou elaborar novas. Desta forma, propor soluções eficientes que auxiliem tanto a população quanto as autoridades no combate ao furto de veículos é uma necessidade vigente, pois ao mesmo tempo em que inibe o criminoso, também tranquiliza o proprietário quanto à segurança de seu patrimônio.

Este trabalho tem por objetivo geral estudar a viabilidade do uso de Redes Neurais Artificiais para a detecção de condução desautorizada de veículos. Para tanto, se propõe a treinar uma rede neural artificial, utilizando como dados de entrada,

informações do próprio veículo, obtidas de um sistema de diagnóstico veicular, conhecido como OBD II. A utilização mais comum do dispositivo OBD II é voltada para a detecção de defeitos nos sistemas do veículo. No entanto, este trabalho procurou apresentar uma nova funcionalidade ao dispositivo e demonstrar que algumas informações obtidas podem contribuir para a compreensão do comportamento do condutor veicular e, com isso, classifica-lo de acordo com seu estilo de direção, por meio de uma rede neural artificial. Esta classificação permite afirmar com elevado grau de certeza, se um condutor pode ser autorizado ou não a conduzir um veículo.

Espera-se que, com os resultados desta pesquisa, seja possível estabelecer um padrão de dirigibilidade que identifique de forma inteligente, a legitimidade do condutor veicular.

Este trabalho está organizado de acordo com a seguinte estrutura: na seção 2 são apresentados os fundamentos teóricos necessários para a obtenção de dados e treinamento da rede neural artificial; a seção 3 apresenta os métodos empregados para o treinamento da rede neural e análise dos dados obtidos; a seção 4 apresenta os resultados obtidos após o treinamento da rede neural artificial e posterior desenvolvimento de um sistema antifurto; a seção 5 apresenta as conclusões geradas pela observação dos resultados e implementação do sistema.

2. REVISÃO BIBLIOGRÁFICA

Neste tópico, serão abordados os aspectos teóricos necessários para a compreensão dos métodos empregados no desenvolvimento do sistema neural antifurto veicular proposto.

2.1 O comportamento do motorista

Obter e analisar dados relacionados ao comportamento do motorista ao dirigir tem sido o foco de vários estudos, seja para realizar simulações, prevenir acidentes ou compreender, sob o aspecto psicológico, as ações tomadas por condutores de veículos. Identificar comportamentos que possam oferecer risco ao condutor, pedestres e fatores de trânsito em geral é o passo inicial para apresentação de soluções para diversos problemas relacionados à condução de automotivos.

Newman et al (2011) [10] afirmam que a direção ocupacional, executada por trabalhadores de transporte de cargas, polícia e serviços de emergência, é responsável por grande parte dos acidentes no trabalho. Os autores propuseram um estudo com o objetivo de apontar os tipos de comportamentos inseguros ao dirigir no contexto ocupacional, baseando-se em estatísticas internacionais que afirmam que a maioria dos acidentes com mortes no trabalho são causados pelo comportamento inseguro do motorista.

Chong et al (2013) [5] propuseram um modelo em rede neural baseado em regras para simular o comportamento do condutor em termos de ações longitudinais e laterais associadas a condições de tráfego que levam a situações críticas de segurança e, então ser possível fazer comparações com dados naturalistas.

Meseguer et al (2013) [10] desenvolveram uma pesquisa para avaliar o comportamento do motorista em sistemas de eco-driving, com ênfase na identificação dos principais fatores que afetam o consumo de energia, tais como: economia de combustível, mudanças bruscas na aceleração e alta velocidade. Os autores aplicaram técnicas de mineração de dados e redes neurais para gerar uma classificação dos estilos de direção de

usuários baseada em seus traços de mobilidade. Para recolher os dados do veículo, foi empregada uma interface OBD-II bluetooth. Os autores concluíram que a classificação do estilo de dirigir do motorista por uma rede neural apresenta alta correlação com os comportamentos observados em ambiente real.

Considerou-se como relevante para esta pesquisa, o trabalho desenvolvido por Shi-Huang Chen, Jeng-Shyang Pan e Kaixuan Lu (2015) [14], que propuseram um modelo de análise de comportamento de condutores baseado em informações provenientes de um dispositivo denominado OBD-II (*On Board Diagnostic*) e algoritmos Adaboost que coletam informações do veículo como velocidade, rotação do motor, posição do acelerador. Este método faz uso de algoritmos Adaboost que criam um modelo de classificação do comportamento do condutor veicular, podendo determinar se o comportamento do motorista atual pertence ou não a uma categoria segura.

Esta e outras pesquisas refletem a preocupação em obter e analisar o comportamento do motorista por meio de diversas técnicas, para atingir diferentes objetivos. Percebe-se que modelos que empregam redes neurais artificiais propiciam uma compreensão satisfatória deste comportamento e oferecem informações significativas para a tomada de decisões de diversos aspectos, principalmente do que diz respeito à segurança do condutor, pois são capazes de analisar e processar uma quantidade considerável de dados em um tempo adequado de resposta.

2.2 O sistema OBD-II

A obtenção de informações para diagnóstico de um veículo pode ser conseguida por meio de um sistema denominado *On Board Diagnostic*, ou simplesmente OBD-II. Este dispositivo é incorporado ao computador de bordo de veículos mais modernos com o objetivo de monitorar diversos componentes e sistemas [11]. A padronização de conectores de OBD II compreende uma interface de 16 pinos (2x8), de acordo com a norma SAE (Society of Automotive Engineers) J1962 ou ISO 15031-3. O conector OBD II deve estar localizado até 0,61m do volante, ao alcance do motorista [3]. A figura 1 mostra um modelo de conector OBD II.



Figura 1. Conector macho OBD-II [12]

Atualmente, emprega-se a segunda geração de OBDs, o OBD II, utilizado desde 1996, que é uma evolução do padrão OBD I. Também especifica o tipo de conector utilizado, pinos, sinais elétricos e formato de comunicação [3]. Este sistema é capaz de monitorar os componentes que afetam o desempenho de um veículo, emitindo avisos ao condutor que o auxiliam a tomar providências cabíveis para cada situação monitorada, como por exemplo, o momento em que se faz necessária uma revisão de rotina no automóvel [7].

Todos os automóveis com OBD-II adotam um código de diagnóstico de problemas padronizado e a interface de conexão ISO J1962. Vários sistemas de controle internos do carro recebem a entrada de informações sobre o estado do veículo a partir de

sensores instalados em várias partes do mesmo. Tais informações podem ser obtidas, externamente, via conector OBD-II [2].

As informações obtidas do computador de bordo dos veículos modernos, por meio do OBD-II, ajudam a melhorar a compreensão da relação entre os hábitos de direção e o desempenho do veículo [7]. As informações captadas podem ser baixadas e transmitidas por um serviço de telefonia celular para ajudar em reparos remotos, por exemplo.

2.3 Redes Neurais Artificiais

Uma das características mais importantes das Redes Neurais Artificiais (RNA) está em sua capacidade de aprender a partir da apresentação de amostras (padrões) que exprimem o comportamento de um sistema. Após o aprendizado a partir do relacionamento entre as entradas e saída da rede, esta é capaz de apresentar soluções generalizadas que se aproximam daquelas esperadas a partir de quaisquer sinais inseridos em suas entradas [15].

O processo de treinamento de uma rede neural exige a aplicação de passos ordenados necessários para o ajuste dos pesos sinápticos e limiares de seus neurônios para que seja possível a generalização de soluções. O conjunto destes passos, é denominado de algoritmo de aprendizagem [15].

Normalmente, o conjunto total de amostras disponíveis sobre o comportamento do sistema é dividido em dois subconjuntos, denominados de dados de treinamento e dados de teste. O subconjunto de treinamento pode ser composto por cerca de 60% a 90% da totalidade das amostras. Já o conjunto de teste é formado por 10% a 40% da totalidade das amostras do sistema e é empregado para verificar se os aspectos relacionados à generalização de soluções já se encontram em patamares aceitáveis. Durante o treinamento da rede neural, cada apresentação completa das amostras, pertencentes ao subconjunto de treinamento, cujo objetivo é ajustar os pesos sinápticos é denominada de época de treinamento [15].

O treinamento de redes neurais pode ser realizado das seguintes formas [4]:

1 - Supervisionado: implica a existência de um supervisor, responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada, comparando-as com a saída desejada. A resposta da rede é função dos valores atuais do seu conjunto de pesos, que são ajustados de forma a aproximar da saída desejada. Este tipo de treinamento é recomendado para problemas em que se deseja obter um mapeamento entre padrões de entrada e saída. São exemplos de treinamento supervisionado os algoritmos de regra delta e sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation*.

2 - Não-supervisionado: não há um supervisor externo para acompanhar o processo de aprendizado. Durante o processo de aprendizado, os padrões de entrada são apresentados continuamente à rede. A existência de regularidades torna possível o treinamento. O treinamento não-supervisionado é adequado a problemas que visam a descoberta de características estatisticamente relevantes nos dados de entrada, como a descoberta de agrupamentos ou classes.

3 - Por reforço: considerado na literatura como um caso particular de treinamento supervisionado. Avalia constantemente a defasagem de valor entre a resposta produzida pela rede em relação à respectiva saída desejada. Os algoritmos ajustam os parâmetros internos dos neurônios por meio de quaisquer

informações quantitativas ou qualitativas provenientes da interação com o sistema ou ambiente que está sendo mapeado, para então utilizá-las para medir o desempenho do aprendizado. O processo de treinamento da rede é realizado tipicamente por tentativa e erro. Quando a resposta é considerada satisfatória, são efetuados aumentos graduais nos pesos sinápticos e limiares, visando reforçar a condição comportamental envolvida com o sistema.

Na aprendizagem usando lotes de padrões (*off-line* ou *batch*), os ajustes efetuados nos vetores de pesos são só realizados após a apresentação de todo o conjunto de treinamento, pois cada passo de ajuste leva em consideração o total de desvios observados nas amostras de treinamento frente aos respectivos valores desejados para as saídas [15]. Na aprendizagem em lotes, as redes necessitam de pelo menos uma época de treinamento para ajustar seus pesos.

Na aprendizagem usando padrão-por-padrão (*on-line*), os ajustes nos pesos são efetuados após a apresentação de cada amostra de treinamento. Assim, após a execução do passo de ajuste, a respectiva amostra pode ser descartada. Este tipo de aprendizagem é empregado quando o comportamento do sistema sofre variações de forma bastante rápida, sendo quase impraticável a adoção do aprendizado *off-line*, devido ao fato de que amostras utilizadas em um determinado instante podem não mais ser úteis em instantes posteriores. Desta forma, a rede só passará a apresentar respostas mais precisas, decorrido um número significativo de amostras.

2.4 O algoritmo backpropagation

O algoritmo *backpropagation* é aplicado durante o processo de treinamento em redes Perceptron Multicamadas (PMC), também conhecido como algoritmo de retropropagação de erro. O processo de treinamento em redes PMC é comumente realizado em duas fases. A primeira, denominada *forward*, os sinais de uma amostra do conjunto de treinamento são inseridos na entrada da rede e propagados camada a camada até a produção das respectivas saídas. As respostas produzidas pelas saídas da rede são comparadas com as respostas desejadas. Os erros entre as respostas desejadas e aquelas produzidas pelos neurônios de saída são, então, calculados e serão usados em seguida para ajustar pesos e limiares de todos os neurônios.

Em função dos valores de erros, aplica-se em seguida a segunda fase do algoritmo *backpropagation*, denominada *backward*, na qual os ajustes dos pesos sinápticos e limiares de todos os neurônios são executados. As aplicações sucessivas de *forward* e *backward* fazem com que os pesos sinápticos e os limiares dos neurônios sejam ajustados automaticamente a cada iteração, provocando uma gradativa diminuição da soma dos erros produzidos pelas respostas em comparação às saídas desejadas.

No decorrer do treinamento, pode ser empregado o termo *momentum*, que se configura como uma das variações mais simples de ser efetuada no algoritmo *backpropagation*. Trata-se de um parâmetro que visa ponderar o quanto as matrizes sinápticas foram alteradas entre as diversas iterações da rede. Seu valor está compreendido entre 0 e 1. Assim, quando o valor do *momentum* for igual a zero, tem-se o *backpropagation* convencional. Para valores diferentes de zero, a taxa de *momentum* passa a ser relevante, pois quando a solução atual estiver longe da solução final, a variação na direção oposta ao gradiente da função erro quadrático entre duas iterações sucessivas será também grande. Isto significa que há uma

diferença considerável entre as matrizes de pesos entre as iterações, cabendo imprimir um incremento maior aos pesos em direção ao mínimo da função erro. O termo *momentum* é o responsável pela medição desta variação [15].

A Figura 2 ilustra a contribuição do termo *momentum* (TM) e do termo de aprendizagem (TA) visando a convergência em direção ao erro mínimo.




Figura 2. Processo de treinamento usando o método de inserção do termo de *momentum* [15]

3. METODOLOGIA

Neste tópico, estão descritos os métodos empregados para o treinamento da rede neural e preparação para o desenvolvimento do sistema de identificação do condutor de veículo.

3.1 Seleção do material

Uma vez que o objetivo principal deste trabalho é desenvolver um sistema inteligente de classificação de condutores de veículos, optou-se por utilizar o dispositivo OBD-II como meio de obtenção de dados para alimentar as entradas de uma Rede Neural Artificial. Este dispositivo é conectado ao computador de bordo do veículo e transmite os dados passíveis de obtenção por meio de uma conexão *bluetooth*, específica do modelo utilizado neste trabalho.

As informações obtidas do computador de bordo dos veículos modernos, por meio do OBD II, ajudam a melhorar a compreensão da relação entre os hábitos de direção e o desempenho do veículo [7].

Para receber os dados provenientes do OBD-II, foi utilizado o aplicativo Torque, cujas especificações estão disponíveis em <http://torque-bhp.com>. O aplicativo é oferecido nas versões gratuita e paga para a plataforma Android. Permite selecionar os dados a serem obtidos, gerando um arquivo no formato .csv que contém as informações monitoradas. Este arquivo foi utilizado na filtragem dos dados.

A Figura 3 mostra um exemplo de parte de um arquivo gerado pelo Torque, contendo dados recebidos pelo smartphone Android via Bluetooth. Nela, pode-se observar a obtenção da posição do pedal do acelerador, a aceleração em x (reta) e a aceleração em y (subida).

	M	N	O
1	Throttle Position(Manifold)	Acceleration Sensor(X axis)	Acceleration Sensor(Y axis)
2	-	-0.10162415355443954	0.4537490904331207
3	22.352941513061523	-0.10617223381996155	0.4568381607532501
4	21.568628311157227	0.12100950628519058	-0.0089437346905465
5	21.176471710205078	0.15045538544654846	0.0058577572926878
6	23.13725471496582	0.09717872738838196	0.0150659149512648
7	27.05882453918457	0.1725456267595291	0.0047254026867449
8	26.27450942993164	0.22347359359264374	-0.0165109112858772
9	28.627450942993164	0.008326227776706219	0.0369259566068649
10	29.019607543945313	-0.07610884308815002	-0.0121494801715016

Figura 3. Exemplos de dados preliminares obtidos pelo aplicativo Torque durante teste com condutor

3.2 Pré-processamento dos dados

Os dados são obtidos do OBD-II em intervalos de 2 segundos, a fim de capturar informações com maior detalhamento. Isto gera um número considerável de amostras, sendo importante filtrá-las. O processo de filtragem ajuda a eliminar ruídos que podem gerar informações incorretas ao sistema e também excluir valores discrepantes para cima ou para baixo que podem fornecer resultados incoerentes. Assim, considera-se o método das médias móveis importante neste sentido, pois é apropriado quando se tem uma série temporal cuja componente sazonal varia com o tempo, ou seja, para séries cuja sazonalidade é estocástica [16].

A média móvel mostra o valor médio dos dados em determinado período, conforme a seguinte fórmula:

$$M_t = \frac{(R_t + R_{t-1} + R_{t-2} + \dots + R_{t-n+1})}{n} \quad (1)$$

onde:

M_t : Média móvel do período t

R_t : Valor real observado no período t

n: Número de períodos considerados na média móvel

As médias móveis são utilizadas para suavizar ruídos, de maneira que seja fácil identificar e definir tendências. O resultado da média móvel depende dos valores cuja média está sendo calculada e a amplitude do intervalo temporal desejado.

3.3 Implementação da Rede Neural Artificial

Para treinar uma RNA com a tarefa de classificar um condutor veicular como sendo autorizado ou não a dirigir um automóvel, é preciso estabelecer alguns parâmetros e critérios, de acordo com a metodologia de Redes Neurais Artificiais (RNA), a saber:

- Separar dados para treinamento e teste;
- Normalizar os dados;
- Definir a arquitetura da rede (número de neurônios na camada de entrada, camada escondida e camada de saída; número de camadas escondidas; escolha da função de ativação);
- Seleção do algoritmo de treinamento;
- Definição da taxa de aprendizado e termo momento;

- Definir critérios de parada de treinamento.

O uso correto desta metodologia implica a separação dos dados a serem analisados em duas partes: dados de treinamento para calibrar a rede e dados de teste para validá-la. Para este trabalho as seguintes variáveis de entrada, obtidas do OBD-II foram utilizadas: posição do acelerador, aceleração em x (reta), aceleração em y (subida) e aceleração em z (curva). Estas variáveis foram selecionadas preferencialmente, baseando-se nos resultados obtidos por [14], cujo estudo apresenta objetivos referentes à análise de riscos apresentados pelo motorista, empregando, também, estas variáveis e mostrando resultados relevantes. Neste trabalho, de um total de 4298 amostras, separou-se 80% dos dados obtidos para treinamento e 20% para teste. O treinamento e testes foram realizados em uma máquina com processador Xeon quadcore, 32 GB de memória RAM e HD de 500 GB.

Para uma melhor classificação, os dados devem estar definidos sob determinados limites, a fim de evitar que valores de uma determinada magnitude possam inviabilizar alguns tipos de modelos. Dependendo da aplicação e/ou tecnologias empregadas, é comum que os dados sejam normalizados, dividindo-se os valores de entrada pelo valor máximo do conjunto de dados, obtendo-se, assim, valores entre 0 e 1. Para este trabalho, esta normalização não foi necessária, uma vez que as bibliotecas Python empregadas, disponíveis em [13], fazem o pré-processamento dos dados, entregando-os já normalizados.

A função de ativação utilizada foi a sigmoide, pois fornece a saída no intervalo de 0 a 1. Assim, optou-se por classificar um condutor como sendo 1 para um condutor autorizado e 0 para um condutor desautorizado.

Foram utilizadas redes de múltiplas camadas, compreendendo uma camada de entrada, 2 camadas escondidas e uma camada de saída. Foram utilizados 10 neurônios na camada de entrada e 10 neurônios nas camadas escondidas. Estes valores apresentaram melhores resultados durante o treinamento. O algoritmo de aprendizagem empregado foi o *backpropagation*, uma vez que o problema tratado neste trabalho não é caracterizado como linearmente separável. Este algoritmo modifica os pesos da rede de forma orientada, para encontrar na superfície de erro, valores para os pesos sinápticos que minimizam os erros da rede [16]. A Figura 4 ilustra a rede neural utilizada.




Figura 4. Rede neural utilizada

Os testes foram realizados considerando uma taxa de aprendizado de 0,001. Tal valor foi escolhido por apresentar uma variação de erro menor durante as iterações do treinamento. Outros valores foram testados, apresentando consideráveis

oscilações. Uma taxa de aprendizado muito pequena torna o treinamento lento, enquanto que valores muito grandes podem provocar divergência do processo de treinamento [8].

A constante momento pode ou não ser usada no algoritmo de treinamento. Ela é útil para evitar que o processo de aprendizagem termine em um mínimo local na superfície do erro. Seu valor pode variar entre 0 e 1. O valor escolhido foi 0,025. O critério de parada escolhido foi um número de 5000 épocas. Os valores selecionados para o momento e o número de épocas foram os que produziram melhores resultados durante o treinamento.

3.4 Web Service Python

Neste trabalho, para criar um Web Service Python que disponibiliza a função de classificação do condutor, empregando metodologia RNA, foi utilizada a biblioteca SOAPpy. Esta biblioteca permite desenvolver Web Services Python sobre vários protocolos, incluindo o SOAP. Para a execução do Web Service Python, um servidor Web Apache, versão 2, foi configurado em uma máquina Linux.

Uma vez disponibilizado o Web Service, foi desenvolvido um aplicativo Android para enviar os dados recebidos do OBD-II para a classificação na rede neural. A rede neural treinada encontra-se no servidor remoto. O aplicativo recebe os dados do veículo que são armazenados em um arquivo .csv no dispositivo por meio do aplicativo Torque, conectado ao OBD-II e os envia à função do Web Service.

A função remota que está no Web Service recebe os dados de entrada, classifica o condutor baseada na rede neural treinada, armazenada no servidor e retorna a classificação do condutor como sendo um condutor autorizado do veículo ou um condutor desautorizado.

O envio dos dados armazenados no arquivo .csv do dispositivo para o Web Service remoto é realizado através de pacotes UDP (User Datagram Protocol), por meio de um socket de comunicação. No servidor, após o recebimento, os dados são gravados em um arquivo texto. Este arquivo é usado pela função de verificação para recuperar os últimos dados recebidos e enviá-los ao Web Service para a classificação pela rede neural. A figura 5 ilustra este processo.

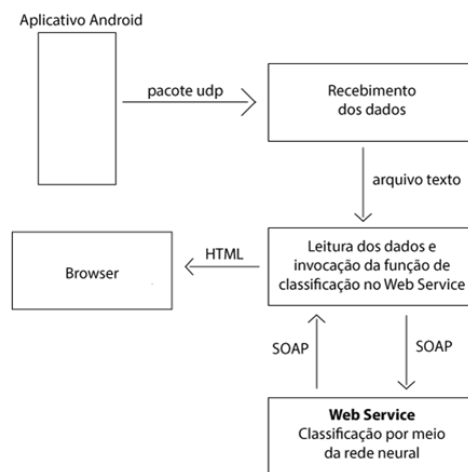


Figura 5. Fluxo dos dados desde o aplicativo Android até a classificação e exibição no navegador

3.5 Preparação dos testes

Para a realização dos testes, foi necessário recolher 20% das amostras compreendendo dados de um condutor autorizado e de condutores não autorizados. Estes valores foram, então, submetidos a uma rotina de testes escrita em Python, a fim de identificar o desempenho do sistema em termos de acertos e erros, o que possibilitou analisar com precisão as respostas fornecidas pela rede neural e o quão poderia ser eficiente sua atuação em um universo real.

4. RESULTADOS

Neste tópico, são apresentados e discutidos os resultados obtidos com o treinamento da rede neural e implementação do sistema antifurto veicular.

4.1 Aplicação de redes neurais artificiais

A utilização de Redes Neurais Artificiais para a classificação de condutores de um veículo segundo informações obtidas do próprio automóvel se mostrou adequada para o auxílio a proprietários de veículos automotivos. Optou-se pelo emprego de redes neurais artificiais neste trabalho, devido à constatação de sua eficiência, comprovada na literatura e por considerar que se apresenta como uma alternativa comprovadamente adequada para a classificação de dados. Percebeu-se que a seleção correta de variáveis de entrada para o treinamento da rede neural é crucial para a obtenção de respostas mais precisas, com menor ocorrência de erros. Algumas variáveis selecionadas no início do estudo tais como velocidade do veículo, rotação do motor e consumo de combustível apresentaram variações muito amenas quando comparadas entre diferentes condutores. Por este motivo, foram descartadas, sendo mantidas apenas aquelas que apresentaram maiores variações, a fim de se obter uma classificação mais confiável.

O cálculo das médias móveis possibilitou suavizar os ruídos gerados na captura dos dados brutos, uma vez que estes são obtidos em um intervalo de 2 segundos pelo OBD-II. Assim, optou-se por fazer uma filtragem, por meio do cálculo de médias móveis em um intervalo de 2 minutos, de forma a caracterizar, com maior precisão, o estilo de cada condutor. Outros intervalos foram testados, porém optou-se por 2 minutos, considerando-se tempo suficiente para que as variáveis fossem recolhidas e utilizadas como dados de entrada confiáveis para a classificação do motorista. A Figura 6 apresenta os dados sem filtragem para a variável posição do acelerador, em um intervalo de 250 segundos. A Figura 7 apresenta um gráfico cujos dados obtidos do dispositivo OBD-II pelo aplicativo Torque foram filtrados por média móvel simples, em janelas de 2 minutos, considerando a variável posição do acelerador.

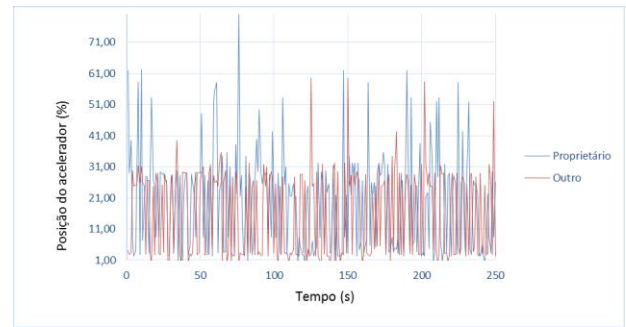


Figura 6. Dados sem filtragem por média móvel para a variável posição do acelerador




Figura 7. Suavização de ruído por média móvel para a variável posição do acelerador

Observa-se que, com os dados brutos, em intervalos de 2 segundos, a complexidade em visualizar e separar as características de dois condutores tomando-se como referência a posição do acelerador, neste caso, é considerável. Por outro lado, ao se aplicar a filtragem por médias móveis, é possível observar melhor os dados e distinções entre dois condutores, pela suavização das curvas para a mesma variável, posição do acelerador.

Foram recolhidas 4298 amostras das variáveis selecionadas entre 3 condutores, sendo um considerado como proprietário autorizado a conduzir o veículo e outros dois como desautorizados. Todos os condutores realizaram os testes no mesmo trajeto em via urbana. A quantidade de amostras por condutor não é exatamente um terço do total, devido às condições diferentes de trânsito em cada teste. Do total de amostras, 80% foi utilizado para treinamento e 20% para testes. A Figura 8 mostra o gráfico de erros ao final do treinamento.

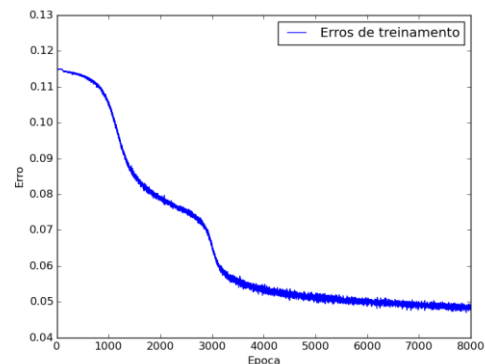


Figura 8. Treinamento com taxa de aprendizagem 0,001 e 8000 épocas

Os 20% das amostras de dados destinados aos testes apresentaram um erro aproximado de 0,045, resultando em 88% de acertos. Outros testes foram realizados, a fim de se encontrar o menor erro e uma porcentagem ótima de acertos. Dentre os testes realizados, a média de acertos foi de 86,2%, com desvio de 1,6% para mais ou para menos ($86,2\% \pm 1,6\%$), conforme mostra a Tabela 1. Esta tabela também apresenta as respectivas taxas de aprendizagem, número de épocas e valor do termo momentum de cada treinamento.

Tabela 1. Média e desvio padrão dos treinamentos realizados

Testes	Taxa de aprendizagem	Épocas	Momentum	Acertos (%)
1	0,0025	5000	0,5	84
2	0,001	10000	0,5	85
3	0,0025	6000	0,5	87
4	0,001	5000	0,5	87
5	0,001	8000	0,025	88
Média				86,2
Desvio padrão				1,6

A avaliação da eficiência da classificação da rede neural foi medida por meio do coeficiente Kappa [6][1]. Os valores de referência são mostrados na Tabela 2 e seu resultado é demonstrado na matriz de confusão da Tabela 3.

Tabela 2. Valor para avaliar o grau de concordância a partir do índice Kappa

Valor do Kappa	Concordância
< 0.20	Pobre
0.21 – 0.40	Fraca
0.41 – 0.60	Moderada
0.61 – 0.80	Boa
0.81 – 1.0	Muito boa

Tabela 3. Matriz de confusão e resultado de coeficiente Kappa

Obtido do OBD		Classificado		
		Autorizado	Desautor.	Total
Obtido do OBD	Autorizado	562	19	581
	Desautoriz.	78	201	279
	Total	640	220	
Kappa = 0,998				

4.2 Comunicação com aplicativo Android

Foi desenvolvido um aplicativo para a plataforma Android, cuja funcionalidade principal é ler os dados do veículo que foram

obtidos do dispositivo OBD-II e armazenados em um arquivo .csv no dispositivo pelo aplicativo Torque. Assim que os dados são lidos, são imediatamente enviados em pacotes UDP, por meio de sockets para o servidor, onde o sistema de classificação de condutores está sendo executado. A classificação é realizada e a resposta é enviada para uma aplicação Web, acessível em qualquer programa navegador. Isto possibilita acessar as respostas fornecidas pelo sistema tanto em um smartphone quanto em qualquer outro dispositivo que suporte um navegador web. A Figura 9 mostra um acesso ao sistema via navegador, para o qual os dados de um condutor foram enviados pelo aplicativo Android ao Web Service. Neste exemplo, a rede neural retornou uma saída igual a 0,032, o que caracteriza um resultado menor que 0,5 considerado como condutor desautorizado pelo sistema.



Figura 9. Resposta do Web Service enviada ao navegador do usuário, caracterizando um condutor desautorizado

A Figura 10 mostra um acesso ao sistema via navegador em que a rede neural retornou uma saída igual a 0,97 caracterizando um condutor autorizado.



Figura 10. Resposta do Web Service enviada ao navegador do usuário, caracterizando um condutor autorizado

5. CONCLUSÃO

O uso de Redes Neurais Artificiais para a classificação do condutor mostrou-se viável e eficaz para este fim. Também é importante ressaltar que o dispositivo OBD-II pode ser empregado para outras finalidades que vão além do diagnóstico dos componentes do veículo para sua correta manutenção. O sistema desenvolvido comprovou que é possível avaliar o comportamento do motorista por meio de dados fornecidos pelo próprio veículo que este conduz.

Propõe-se como opção para estudos futuros, realizar testes com um conjunto maior de motoristas, a fim de reforçar a confiabilidade dos resultados. Estudos futuros poderão, ainda, adicionar outras funcionalidades ao sistema, tais como envio de SMS ao proprietário do veículo, contendo informações sobre a condução desautorizada; envio da localização geográfica do veículo, em caso de condução desautorizada; envio de sinais ao veículo para a interrupção de um ou mais sistemas e utilização do sistema com um microcontrolador para obter os dados do veículo e enviar ao servidor para a classificação.

O sistema proposto, além de uma preciosa contribuição científica, também apresenta um grande potencial comercial, comprovado pelas necessidades atuais em segurança de bens patrimoniais e, certamente pode ser empregado para estes fins em um futuro bem próximo.

6. AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPEMIG - Fundação de Amparo a Pesquisa do Estado de Minas Gerais - para a publicação deste artigo.

7. REFERÊNCIAS

- [1] Araújo, N. V. de S.; Shinoda, A. A.; Oliveira, R. de. Kappa-artmap fuzzy: uma metodologia para detecção de intrusos com seleção de atributos em redes de computadores. SBRC, Universidade de Brasília, Brasília - DF, Brasil, 2013.
- [2] Baek, S. H. Implementation Vehicle Driving State System with. 17th Asia-Pacific Conference on Communications (APCC). Sabah - Malasya: [s.n.]. 2011.
- [3] Bastos, E. Estudo das diferenças dos requerimentos das principais legislações de On Board Diagnostics para padronização de testes de desenvolvimento e validação de transmissão automática de automóveis. Centro Universitário do Instituto Mauá de Tecnologia. São Caetano do Sul, p. 58p. 2012.
- [4] Braga, A.P; Carvalho, A.P.L.F; Ludermir, T. B. Redes neurais artificiais: teoria e aplicação. 2 ed. São Paulo: LTC, 2014.
- [5] CHONG, L. et al. A rule-based neural network approach to model driver naturalistic behavior in traffic. *Transportation Research Part C: Emerging Technologies*, v. 32, p. 207-223, 2013.
- [6] Cohen, J. et al. A coefficient of agreement for nominal scales. *Educational and psychological measurement*, Durham, v. 20, n. 1, p. 37-46, 1960.
- [7] Godavarty; Broyles, S.; Parten, M. Interfacing to the on-board diagnostic system. *Vehicular Technology Conference*, Boston, v. 4, n. 52, p. 2000-2004, september 2000.
- [8] Haykin, S. *Neural networks, a comprehensive foudation*. New Jersey: Englewood Cliffs. 2001. 842p.
- [9] Huang, S. H.; Zhang, H.-C. Applications of neural networks in manufacturing: a state-of-the-art survey. *International Journal of Production Research*, 33, n. 3, 2007. 705-728.
- [10] MESEGUER, J. E. et al. DrivingStyles: A smartphone application to assess driver behavior. *IEEE Symposium on Computers and Communications (ISCC)*, Split, Croatia, p. 435-540, 2013.
- [11] NEWMAN, S. et al. Safety in occupational driving: development of a driver behaviour scale for the workplace context. *Applied Psychology*, v. 60, n. 4, p. 576-599, 2011.
- [12] OBD-II. The OBD-II Home Page. Disponível em: <http://www.obdii.com/background.htm>. Acesso em: 15 dez. 2015.
- [13] Pybrain. The Python learning machine library. Disponível em: <http://pybrain.org>. Acesso em: 11 jan. 2016.
- [14] Shi-Huang Chen; Jeng-Shyang Pan; Kaixuan Lu. Driving Behavior Analysis Based on Vehicle OBD Information and AdaBoost Algorithms. *Proceedings of the International MultiConference of Engineers and Computer Scientists*, v. 1, 2015.
- [15] Silva, I. N; Spatti, D. H; Flauzino, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artiber, 2010.
- [16] Villamagna, M. R. Seleção de modelos de séries temporais e redes neurais artificiais na previsão de consumo e demanda de energia elétrica. *Dissertação (mestrado)*. Lavras: UFLA, 2013. 113p.