APLICAÇÃO DAS PRINCIPAIS TÉCNICAS DE APRENDIZADO DE MÁQUINA NA SEGURANÇA VIÁRIA – ESTADO DA ARTE

Rodrigo Aguiar
Adelino Ferreira
Centro de Investigação em Território, Transportes e Ambiente (CITTA)
Departamento de Engenharia Civil
Universidade de Coimbra

RESUMO: A busca para o entendimento de ocorrência dos sinistros de trânsito está se tornando cada vez mais comum. Os estudos não se limitam apenas à segurança rodoviária, mas também está se expandido para outras áreas além da engenharia. O uso da inteligência artificial está sendo tema em diversas tomadas de decisões. Com a segurança viária não está sendo diferente. Algoritmos estão sendo desenvolvidos no intuito de aprimorar a modelagem estatística dos modelos preditivos existentes, estes chamados Aprendizados de Máquina fazem parte de um subgrupo da Inteligência Artificial. Este trabalho apresenta o Estado da Arte da aplicação de técnicas de Aprendizado de Máquina mais utilizadas na segurança viária, com base em pesquisas nas revistas científicas mais importantes. São elas: as Redes Neurais Artificiais (RNA), Árvores de Decisão (AD) e Maquinas de Vetores de Suporte (MVS).

Palavras-Chaves: Segurança Viária. Inteligência Artificial. Aprendizado de Máquina. Estado da Arte.

ABSTRACT: The search for understanding the occurrence of traffic accidents is becoming increasingly common. The studies are not just limited to road safety, but it is also expanding to other areas besides engineering. The use of artificial intelligence is being the subject of several decision-making. With road safety it is no different. Algorithms are being developed in order to improve the statistical modeling of existing predictive models, called Machine Learning are part of a subgroup of Artificial Intelligence. This work presents the State of the Art of the application of Machine Learning techniques most used in road safety, based on research in the most important scientific journals. They are: Artificial Neural Networks (ANN), Decision Trees (DT) and Support Vector Machines (SVM).

Keywords: Road Safety. Artificial intelligence. Machine Learning. State of art.

1. INTRODUÇÃO

A segurança no trânsito vem se tornando um tema bastante relevante ao longo da última década. O alto índice de sinistros de trânsito, levam à grandes perdas econômicas aos países, principalmente os em desenvolvimento. De acordo com o Organização Mundial da Saúde (OMS, 2015), os sinistros de trânsito são uma das principais causas de mortes no mundo, entre pessoas com idades entre cinco e 29 anos. São 1,35 milhões de mortes e 50 milhões de feridos anualmente em sinistros, nos quais 90% das vítimas são de países em desenvolvimento.

Na procura de soluções para tentar reduzir o número de fatalidades e feridos nos sinistros, órgãos governamentais, juntamente com a comunidade científica, vêm trabalhando em diversos meios de intervenções para a melhoria da segurança viária. Uma delas, é o uso da

Inteligência Artificial (IA) que aliados com métodos estatísticos existentes, vêm sendo utilizados atualmente para modelos preditivos.

IA é um campo da ciência e engenharia da computação que procura reproduzir os sistemas inteligentes, associados às características humanas, como resolução de problemas, raciocínio lógico, visão, compreensão e aprendizagem (Facelli *et al.*, 2011).

Este artigo tem como objetivo, apresentar técnicas de IA mais encontradas na literatura em modelos de previsão. Estes modelos servem para analisar, identificar os pontos críticos, e com isso, tentar prever a frequência e gravidade dos sinistros. Os trabalhos mais importantes foram relacionados por relevância para a pesquisa e sua ordem cronológica.

2. INTELIGÊNCIA ARTIFICIAL

A necessidade do homem em aprender e realizar tarefas que dependam de inteligência, o levou a desenvolver diversos sistemas computacionais. Sistemas esses que poderiam ser capazes de substituir o ser humano nessas tarefas. Muitas dessas pesquisas para a construção desse tipo de software e sistemas computacionais podem ser classificados como Inteligência Artificial (IA) (Nilsson, 2014). Nilsson define também a IA como uma subárea da ciência computacional, em que se proporciona aos computadores, a maneira de agir inteligentemente.

O Aprendizado de Máquina (AM) é um ramo da IA, onde máquinas desenvolvem tarefas que seriam executadas por pessoas. Para isso, o sistema deve possuir habilidade para aprender com novas informações e ser inteligente (Alpaydin, 2009). No AM são utilizados algoritmos para coletar dados, fazendo com que os computadores tomem decisões baseadas no seu próprio conhecimento que foi adquirido ao longo do tempo para a resolução dos problemas (Lecun *et al.*, 2015). Essa habilidade faz o Aprendizado de Máquina ser capaz de ajudar na solução de diversos problemas, incluindo reconhecimento de fala, robótica, processamento e reconhecimento de imagens.

Segundo Alpaydin (2009) um modelo de aprendizado de máquina pode ser configurado de acordo com parâmetros, e o aprendizado é feito por meio da execução de um programa de computador que otimizará os parâmetros do modelo usando dados de treinamento ou experiências passadas. O modelo pode ser preditivo, para fazer predições futuras, descritivo, para aprender conhecimento com os dados, ou ambos.

O modelo de AM é operado por meio de algoritmos que recebem dados de entrada, a fim de fazer previsões. Essa tarefa é composta por três etapas: inicialmente a criação do modelo, que de acordo com as classes definidas, definirá o problema; o treinamento, onde uma função é criada pelo algoritmo para descrever os dados em relação às classes do problema; e por fim, a validação do modelo, verificando a sua eficácia. Os dados que são usados nessa etapa, não são os mesmos da etapa de treinamento (Facelli *et al.*, 2011).

A forma de aprendizagem ocorre, basicamente, de três formas distintas: supervisionado, não supervisionado e semi-supervisionado. A modelagem da segurança viária é apta de ser realizada mediante o aprendizado supervisionado, pois esse fenômeno pode ser representado em uma base de dados com valores de saída conhecidos, como a frequência ou severidade de sinistros.

Foram encontradas na literatura diferentes tipos de aprendizagem de máquina. Os mais utilizados foram: Redes Neurais Artificiais (RNA), Árvores de Decisão (AD) e Máquinas Vetores de Suporte (SVM), que serão abortados nesse artigo.

2.1 Redes Neurais

O desenvolvimento das redes neurais foi inspirado na estrutura e no funcionamento do sistema nervoso, tendo como objetivo simular a capacidade de aprendizado do cérebro humano na aquisição do conhecimento (Facelli *et al.,* 2011).

São sistemas computacionais distribuídos, compostos de unidades de processamento simples, densamente interconectados, conhecidos como neurônios artificiais, que computam funções matemáticas. É indicado em casos de fenômenos não bem conhecidos ou provenientes de fatores multicausais, em que o método analítico tradicional, demandaria muito tempo computacional (Mussone, *et al.*, 1999).

Na modelagem, os dados de acidentalidade viária, a rede neural geralmente é constituída de múltiplas camadas (MLP – Multilayer Perceptron), treinado com base geralmente, pelo algoritimo Back-Propagation. A aplicação deste algoritimo é baseada na regra delta generalizada, constituída por duas fases: para frente (Forward) e para trás (backward) (Facelli *et al.,* 2011).

Os valores das variáveis explanatórias são depositados na camada de entrada, no caso, os dados de sinistros como: características ambientais, veiculares e humanas. Nas camadas ocultas, o peso é aplicado nos valores de entrada e são calculados os padrões de associação. Finalmente na camada de saída, é apresentada a soma dos valores dos neurônios ocultos. A figura 1 a seguir, apresenta a estrutura da RNA com MLP, geralmente utilizada na modelagem do banco de dados dos acidentes:

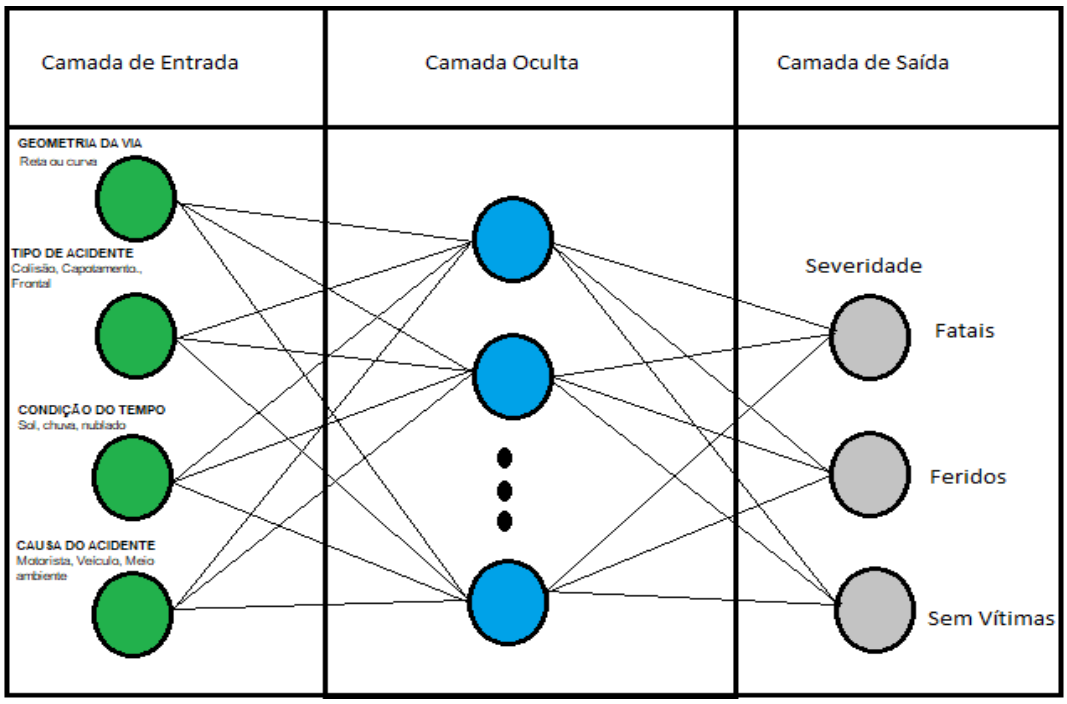


Figura 1 – Representação de uma Rede neural artificial

Na prática, a modelagem tem início pela extração aleatória de dois subconjuntos de dados: o de treino, com 70% dos dados, e o de teste, com os 30% restantes. Vale ressaltar que estes conjuntos não podem ser muito grandes, pois podem dificultar o processo de aprendizagem da RNA. Além disso, os subconjuntos devem ser o mais homogêneo possível, pois o aprendizado tem como base, o maior número de combinações possíveis.

O estudo de caso realizado por Mussone *et al.* (1996), foram utilizadas redes neurais em rodovias na Itália. A capacidade de agrupamento permitiu uma avaliação interpretativa de cada variável de entrada em sua influência no número de sinistros.

Outro estudo realizado por Mussone *et al.* (1999), os pesquisadores utilizaram as RNA para modelar a periculosidade das interseções urbanas em Milão. A complexibilidade da interseção pode determinar um maior índice de sinistros. Também no mesmo estudo, ficou constatado que a maioria dos atropelamentos de pedestres acontece em cruzamentos não sinalizados no período da noite.

Ozyan e Demirci (2008) realizaram um estudo de caso de aplicação de RNA em rodovias rurais interurbanas para frequência de sinistros. Foi demonstrada a eficácia de seu mapeamento não linear. Os resultados provaram ser um modelo razoavelmente preciso.

Cansiz (2011) mostrou que a estimativa do número de mortos pode ser melhorada com precisão dos modelos de RNA. Os modelos podem fazer esta previsão com alto coeficiente de correlação e baixo MSE.

Estudos para comparar modelos estatísticos tradicionais e Redes Neurais também se destacam. O uso de RNA para análise de frequência de sinistros, não requer nenhuma pré-relação subjacente entre as variáveis independentes e dependentes, podendo assim, ser uma ferramenta poderosa para problemas de previsão e classificação. Com isso, Chang (2005) comparou um modelo de RNA, com modelo estatístico de Regressão Binomial Negativa (RBN). Este modelo tradicional vem sendo usado há muitos anos para análise de frequência de sinistros. Como resultado, a RNA se mostrou um pouco melhor que o modelo estatístico, para trechos com um ou mais acidentes. Já o modelo RBN, foi mais preciso para locais onde não houve nenhum sinistro.

Para identificar aos fatores significativos que influenciam os níveis de gravidade das lesões em motoristas durante o sinistro, Delen *et al.* (2006), criaram 8 modelos de redes neurais binárias. Níveis diferentes de gravidade de lesão foram usados como variáveis dependentes. Nenhum fator isoladamente pareceu ser uma chave determinante para a gravidade do sinistro, mas o modelo pode atuar como um catalisador ou barreira, sendo combinado com outros fatores.

Akgungor e Doyan (2008) realizaram um estudo de caso com dados de 15 anos na nas rodovias da Turquia, analisando modelos analíticos com base em regressão não-linear e RNA. O modelo RNA teve melhor desempenho com menores erros no geral.

O fator humano corresponde a mais de 90% dos fatores causadores de sinistros. Sommer *et al.* (2008), investigaram a validade preditiva de uma RNA em uma bateria de testes, medindo várias habilidades relacionadas à direção e personalidade dos condutores. Os resultados do algoritmo indicaram que a relação entre a aptidão para dirigir, medido por meio de um teste de direção padronizado e habilidades relacionadas à direção e traços de personalidade, não necessariamente precisam ser lineares.

Técnicas de Retropropagação comparadas com o modelo Probit Ordenado (PO) para prever a gravidade dos sinistros, foram estudadas por Chimba e Sando (2009). O modelo de RNA obteve superioridade, com uma acurácia de 83,3%, enquanto PO, teve precisão de 65,5%.

Também para análise de comparação, Karlaftis e Vlahogianni (2011) abordaram o uso de modelos estatísticos e RNA para o desempenho na aplicação em pesquisas em transportes. Os autores destacaram que a precisão é um fator muito importante para comparação entre os modelos, porém não deve ser o único determinante. Outras questões devem ser analisadas

como: tempo e esforço necessário para o desenvolvimento do modelo, habilidades e conhecimentos necessários, transferibilidade dos resultados, adaptabilidade a mudanças de comportamento. É recomendado que as técnicas sejam usadas de forma sinérgica em diferentes estágios da modelagem de dados.

Alikhani *et al.* (2013) utilizaram algoritmos de classificação individual como RNA e sistema de inferência Neuro-Fuzzy Adaptativo (NFA). Uma ideia de método de classificação por agrupamento foi adaptada usando K-means e Self-organization. Os experimentos no conjunto de dados, demonstram que o pré agrupamento pode melhorar a previsão de classificação.

Um algoritmo de Combinação Convexa (CC) foi elaborado por Zeng e Huang (2014), para que o treinamento de uma RNA seja mais estável e rápido, em modelos de previsão de gravidade e lesões. Também foi criado um algoritmo modificado para aproximação de funções para otimização da estrutura de rede. Este algoritmo identifica os fatores insignificantes, realiza a eliminação destes e consequentemente, reduz o tempo de processamento computacional e melhora a capacidade de generalização do modelo. O objetivo foi compará-los com o tradicional Retropropagação (BP) e um modelo Logit Ordenado (LO). Como resultado, o algoritmo CC superou o BP na velocidade de treinamento.

Por ser um método mais flexível e livre de suposições, Çodur e Tortum (2015) desenvolveram modelos de previsão de frequência de sinistros para rodovias rurais de pista dupla na Turquia. Os baixos valores do erro quadrático médio (EQM) e a raiz quadrada do erro médio (REQM), e o alto valor de correlação (R^2), também indicam a superioridade do modelo. Os autores consideraram as características geométricas e operacionais constantes por segmento. Como resultado, foi indicado que a curvatura vertical foi o parâmetro mais importante na influência no número de acidentes nas rodovias estudadas.

Zeng *et al.* (2016a), desenvolveram um modelo de RNA para explorar a relação não linear entre os fatores de risco e a freqüência de sinistros. Um algoritmo de otimização de estrutura de rede e um método de extração de regras foi proposto. Este estudo de caso, também comparou o desempenho dos modelos de RNA treinados, com o NB para freqüência de sinistros em Hong Kong. O modelo de RNA teve desempenho melhor que o tradicional estatístico. Zeng *et al.* (2016b), também desenvolveram no mesmo ano, modelos de RNA para explorar a relação não linear, agora com modelo multivariado Poisson-Lognormal. Novamente a RNA levou vantagem sobre o modelo estatístico.

Mais uma análise de sensibilidade foi realizada, no estudo de Huang et al. (2016). Foi desenvolvida uma função de base radial, usando abordagens de RNA otimizada, com a intenção de aprimorar as relações não lineares entre a frequência de sinistros e os fatores de risco. Mais uma vez foi comparado o modelo com a regressão binomial negativa. Os resultados demonstraram que a RNA com funções radiais, tiveram melhor ajuste e desempenho de previsão que os modelos NB e RNA.

2.2 Árvores de decisão

Como nome diz, uma árvore de decisão é utilizada para resolver um problema de decisão complexo, em problemas mais simples, aplicado a uma mesma estratégia (Facelli *et al.*, 2011). O seu uso é bastante útil nas tarefas de classificação. Os classificadores permitem detectar quais são as melhores variáveis preditoras, através da extração de regras de decisão do tipo “se ---> então”.

Em sua construção é utilizado um conjunto de treinamento formado pelas entradas e saídas. Sua estrutura se inicia por um nó de entrada (nó raiz) e assim, acontece a classificação, sendo dividido em vários nós, que representam uma classe. Os ramos entre esses nós são denominados atributos, de acordo com uma regra. O atributo será um nó da árvore, no qual gera maior ganho de informação (entropia), sendo melhor qualidade de classificação (Trabelsi, *et al.* 2019). Cada regra tem início na raiz da árvore e se desenvolve pelos ramos, finalizando nos nós de decisão. Sendo assim, cada nó terminal ou folha, determina o valor esperado para cada variável. O modelo CART pode ser facilmente compreendido e interpretado, devido à sua natureza gráfica em seus resultados. A estrutura de uma árvore de decisão pode ser vista na figura 2 a seguir:

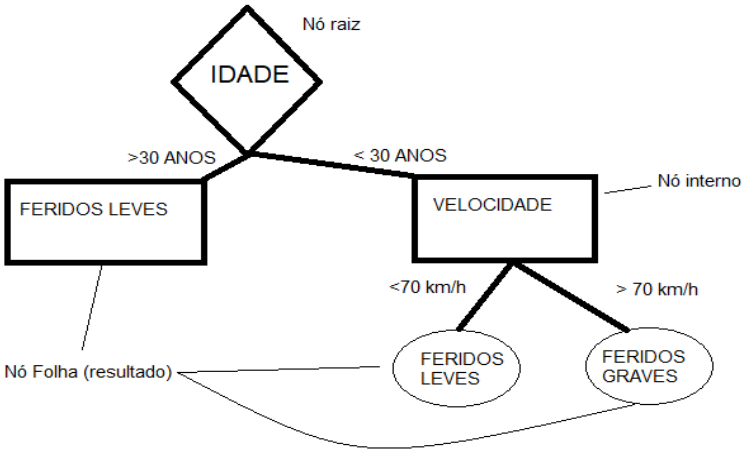


Figura 2 – Árvore de decisão

Foi utilizada a AD por Karlaftis e Golias (2001) para avaliar a relação entre as características geométricas das estradas rurais sobre as taxas de sinistros. Com isso também foram feitos estudos sobre previsão de sinistros para determinados trechos da rodovia.

A metodologia utilizada pó Abdel-Aty *et al.* (2005) foi de regressão baseada em árvores de interseções para compreender os fatores que contribuem para os sinistros.

As árvores de decisão também foram usadas para avaliar o efeito de uma licença de dirigir de um motociclista e motoristas de automóveis. No estudo feito por Magazzu *et al*. (2006), o modelo foi comparado à regressão logística. O resultado encontrado indicou que os motociclistas habilitados têm menos responsabilidades nos sinistros com automóveis, do que os sem habilitação.

Um modelo baseado em CART foi proposto por Chang e Chen (2005) para estabelecer a relação empírica entre acidentes de trânsito e variáveis geométricas da rodovia, características de trânsito e fatores ambientais. Os resultados foram comparados com o modelo tradicional de regressão binomial negativa. Com resultados superiores, o estudo indicou que o CART se torna uma boa alternativa para análise de frequência de sinistros.

Outro modelo baseado em CART proposto por Chang e Wang (2006) serviu para analisar os fatores de risco que podem influenciar a gravidade das lesões nos sinistros. Foi identificado que os pedestres, motociclistas e ciclistas fazem parte dos grupos mais vulneráveis na estrada, demonstrando que o CART é uma boa metodologia para análise de gravidade da lesão. É sugerido, como trabalhos futuros, uma comparação entre os modelos estatísticos e o

CART, para obtenção de informações valiosas sobre a relação entre os fatores de risco e gravidades das lesões.

Parkgohas *et al.* (2010) investigaram a relação entre o fator humano e a gravidade dos sinistros utilizando CART e Regressão Logística (RL). Os resultados indicaram que "carteira de habilitação" e "cinto de segurança" tinham associação com a gravidade de lesão no Irã.

Kashani e Mohaymany (2011) demonstram que a não utilização do cinto de segurança é o fator mais importante para aumentar a gravidade das lesões nos motoristas.

Técnicas de mineração de dados juntamente com um conjunto de regras para vincular características das estradas à gravidade dos acidentes, foram aplicadas por Beshah e Hill (2010) na Etiópia.

Montelaa *et al.* (2011) analisaram os acidentes de motocicletas com também com técnicas de mineração. As análises foram feitar com árvores de classificação e descoberta de regras. Devido ao grande número de padrões, existe o risco de aparecerem padrões por acaso. Por isso, o estudo dividiu aleatoriamente os dados em dois conjuntos. Os métodos se comprovam eficazes em fornecer resultados significativos sobre as características dos acidentes.

O artigo de Oña *et al.* (2013) aplica alguns métodos mais usados para construir AD, visando identificar os principais fatores que contribuem para a gravidade dos acidentes. A aplicação desses métodos permitiu a extração de regras de decisão potencialmente úteis que podem ser usadas por analistas de segurança viária.

A dependência dos fatores de risco para dados foi estudada por Kwon *et al.* (2015) na Califórnia, USA. Dois métodos de classificação e dois algoritmos de pontuação relacionados foram usados para encontrar classificações dos fatores de risco, onde o primeiro método, Naive Bayes (NB), não reflete a dependência, e o segundo método, a AD, sim. As metodologias deste estudo são aplicáveis a outros conjuntos de dados existentes segundo os autores.

Em um estudo bem recente de Chen e Chen (2020), os autores utilizaram Regressão Logísica (RL), CART e Floresta Aleatória (FA). Três medidas de avaliação e desempenho de predição, acurácia, sensibilidade especificidade, foram usadas para encontrar o melhor método integrado que consiste no modelo de predição mais eficaz.

2.3 Máquinas de Vetores de Suporte

As Máquinas de Vetores de Suporte (MVS) são baseadas na teoria de aprendizado estatístico desenvolvido por Vapnik (2005). As MVSs utilizam planos de decisão para encontrar padrões nos dados e classificá-los. A ideia é construir um hiperplano mapeando os dados de classes diferentes, mantendo uma distância máxima entre esses dados. Sendo assim, o MVS escolhe um vetor suporte para cada classe, como visto na figura 3, tendo sua medida usada para diferenciar as classes (Manning *et al*. 2010).

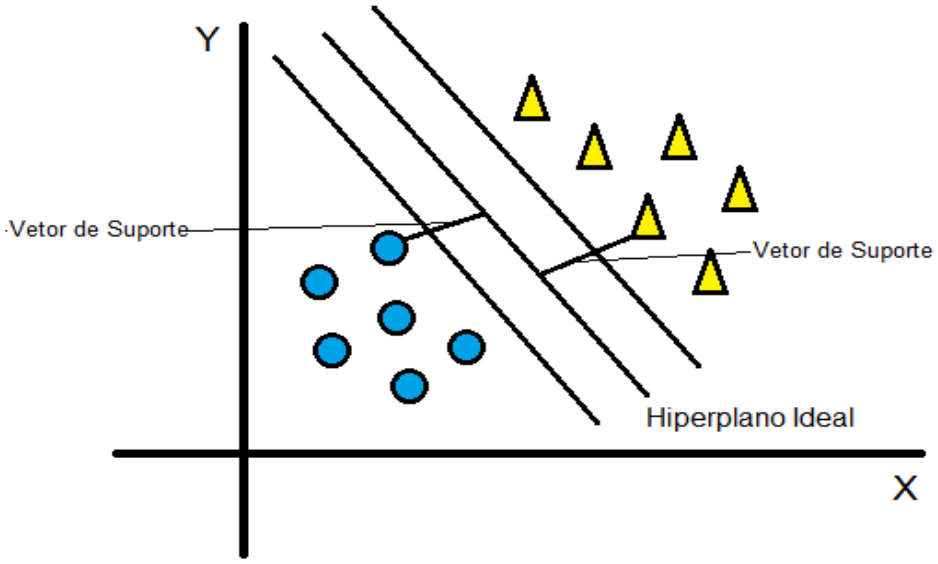


Figura 3 – Máquina Vetor de Suporte

O modelo usando o hiperplano divide o conjunto de amostras em dois grupos: os negativos e os positivos. O maior problema encontrado no modelo é como saber selecionar os valores dos parâmetros de treinamento. Configurações inadequadas levam a resultados de previsão ruins.

O modelo é um método relativamente novo em problemas de classificação, onde tem sido cada vez mais utilizado em pesquisa de sinistros de trânsito. Os resultados de sua aplicação são comparáveis e em algumas vezes superiores a outros algoritmos tradicionais, como por exemplo, os RNA (Facelli *et al*. 2011).

Foram avaliados por Li *et al*. (2008) modelos de MVS na previsão de acidentes demonstrando que estes modelos, prevêem dados com mais eficácia e precisão que os tradicionais NB. Tiveram como característica, não superajustarem os dados em relação à modelos RNA, sendo assim, mais rápidos para implementar.

A combinação entre a técnica de otimização de enxame de partículas e a máquina vetor de suporte, foi apresentada por Ren e Zhou (2011) como uma nova abordagem para previsão de sinistros. Dados de trânsito na China entre os anos de 1970 a 2006 foram analisados. Esta técnica, comparada com a rede neural Back Propagation, apresentou melhores resultados.

Li *et al*. (2012) investigou o uso de MVS para análise da gravidade de lesões nos sinistros. Comparado com um modelo Probit Ordenado (PO), verificou-se que o MVS produziu melhor desempenho em relação ao tradicional estatístico. Como principal conclusão do estudo, o modelo MVS pode ser usado para análises de gravidade das lesões. Porém, um exemplo de limitação é que o desempenho do modelo depende do procedimento de aprendizado que contém mapeamento funcional e seleção de parâmetros.

Foi aplicado o modelo de MVS para avaliar o risco de acidente em tempo real por Yu e Abdel-Aty (2013). Análises de extensão foram realizadas para avaliar o efeito do tamanho da amostra em sua capacidade de predição, como também a importância da seleção das variáveis antes do desenvolvimento dos modelos. Os resultados indicam que o tamanho da amostra menor aumenta a precisão de classificação do modelo como também a eficácia da seleção de variáveis antes da estimativa do mesmo.

Resultados do estudo de Yu e Abdel-Aty (2014), como modelo de SVM, demonstram que o tráfego em tempo real e as variáveis meteorológicas tem influência nas gravidades das lesões de acidentes. Os modelos de parâmetros aleatórios superam os modelos de parâmetros fixos.

Halin *et al*. (2016) apresentaram uma abordagem de várias técnicas baseadas em IA para previsão de acidentes e análise de padrões. Foram citados oito importantes técnicas com as seguintes características: domínio de aprendizagem, melhor precisão, se é adequada para tempo real, se suportam os dados em vários formatos. Como resultados, os melhores modelos foram RNA e árvores de decisão. O estudo também inclui o MVS como uma das técnicas mais utilizadas.

O estudo de Chen *et al.* (2016) investigou a aplicabilidade dos modelos MVS em análises de gravidade de lesões em motoristas e também para examinar padrões de gravidade de lesões dos motociclistas em colisões com capotamento.

3. CONCLUSÕES

A busca de novas alternativas para tentar reduzir as mortes por sinistros de trânsito, fez com que pesquisadores interessados na área de segurança viária, aprimorassem mais suas investigações. Técnicas de Inteligência Artificial, como o Aprendizado de Máquina, aliadas aos tradicionais métodos estatísticos, tornaram os modelos de previsão de acidentes mais eficazes. O intuito deste artigo, foi realizar um estado da arte dos métodos de Aprendizado de Máquina desenvolvidos mais encontrados na literatura. De acordo as pesquisas, os algoritmos mais encontrados utilizados em pesquisas ao longo dos anos, foram: Redes Neurais Artificiais (RNA), Árvores de Decisão (AD) e Máquinas de Vetores de Suporte (SVM). Foram apresentados estudos com uma ordem cronológica de tempo. Com isso, espera-se que este artigo possa auxiliar futuras novas pesquisas relacionadas a este tema.

REFERÊNCIAS

Alikhani, M.; Nedaie, A.; Ahmadvand, A**. Presentation of clustering classification heuristic method for improvement accuracy in classification of severity of road accidents in Iran.** Safety Science, v. 60, p. 142–150, 2013.

Alpaydin, E. **Introduction to machine learning**. MIT Press, 2019.

Akgüngör A.P.; Doğan E. **Estimating Road accidents of Turkey based on regression analysis and artificial neural network approach.** Advances in Transportation Studies International Journal, 2008.

Blincoe, L. J.; Miller, T. R.; Zaloshnja, E. and Lawrence, B. A. **The Economic and Societal Impact of Motor Vehicle Crashes, 2010. (Revised).** National Highway Traffic Safety Administration, Washington, DC, USA, 2015.

Cansız, O. F. **Improvements in estimating a fatal accidents model formed byan artificial neural network**. Simulation.; 87(6):512-522, 2011.

Chang L**. Analysis off reeway accident frequencies: Negative binomial regression versus artificial neural.** Safety Science. 43(8):541-557, 2005.

Chimba, D.; Sando, T. **The prediction ofhigh way traffi caccident injury severity with neuromorphic techniques**. Adv. Transport. Stud. 19 (1), 17–26, 2009.

Çodur, M. Y.; Tortum, A. **An artificial neural network model for highway accident prediction: a case study of Erzurum, Turkey.** Promet –Traffic & Transportation, v. 27(3), p. 217-225, 2015.

Delen, D.; Sharda, R.; Bessonov, M. **Identify insignificant predictors of injury severity in traffic accidents using a series of artificial neural networks.** Accident Analysis and Prevention, v. 38(3), p. 434-444, 2006.

Facelli, K.; Lorena, A. C.; Gama, J. Carvalho. **Inteligência Artificial: Uma abordagem de aprendizado de máquina.** Rio de Janeiro: LTC. 378p, 2011.

Huang, H.; Zeng, Q.; Pei, X.; Wong, S. C. **Predicting crash frequency using an optimized radial basis function neural network.** Transportmetrica A: Transport Science, v. 12(4), p. 330-345, 2016.

Karlaftis, M. G.; Vlahogianni, E. I. **Statistical methods versus neural networks in transportation research: differences, similarities and some insights.** Transportation Research Part C, v. 19, n. 3, p. 387–399, 2011.

Lecun, Y.; Bengio, Y.; Hintonand G. **Deep learning.** Nature, v. 521, n. 7553, p. 436-444, 2015.

Mantovani, V. R.; Raia JR, A. A. **Gestão em Segurança de tráfego Urbano Utilizando o método SIGSET**. Revista dos transportes públicos, n.110 p.29-40, 2006.

Mussone, L.; Rinelli, S.; Reitani, G. **Estimating the accident probability of an vehicular flow by means of an artificial neural network**. Environment and Planning B 23, 667–675, 1996.

Mussone, L.; Ferrari, A.; Oneta, M. **Analysis of urban collisions using an artificial intelligence model.** Accident Analysis and Prevention, v. 31(6), p. 705–718, 1999.

Nilsson, N. J. **Principles of artificial intelligence**. San Francisco, CA: Morgan Kaufmann Publishers, 2014.

OMS. **Global Status on Road Safety**, 2015.

Ozgan, E.; Demirci. R. **Neural Networks-based Modeling of Traffic Accidents In Interurban Rural Highways.** Applied Sci., 8, pp. 146-151, 2008.

Sommer, M.; Herle, M.; Hausler, J.; Risser, R.; Schutzhofer, B.; Chaloupka, C. **Cognitive and personality determinants of fitness to drive.** Transportation Research Part F 11, 362–375, 2008.

Trabelsi, A.; Elouedi, Z.; Lefevre E. **Decision tree classifiers for evidential attribute values and class labels.** Fuzzy Sets and Systems. v. 366, p. 46-62, 2019.

Zeng, Q.; Huang, H. **A stable and optimized neural network model for crash injury severity prediction.** Accident Analysis and Prevention, v. 73, p. 351–358, 2014.

Zeng, Q.; Huang, H.; Pei, X.; Wong, S. C.; Gao, M. **Rule extraction from an optimized neural network for traffic crash frequency modeling.** Accident Analysis and Prevention, v. 97, p. 87–

95, 2016ª.

Zeng, Q.; Huang, H.; Pei, X.; Wong, S. C. **Modeling nonlinear relationship between crash frequency by severity and contributing factors by neural networks**. Analytic Methods in Accident Research, v. 10, p. 12–25, 2016b.