

MAPEANDO ATIVIDADES FÍSICAS POR MEIO DE REDES SOCIAIS

Gabriel Sousa Ferreira, Universidade de Itaúna, gabriel.sofe@gmail.com.
Dr. Marco Túlio Alves Rodrigues, Universidade de Itaúna, tulio.rodrigues@gmail.com.

Resumo: Este trabalho busca mapear a prática de atividades físicas, em um conjunto de imagens adquiridas por meio de redes sociais. A atividade física pode ser eficaz em todos os estágios de doenças crônicas, portanto, encontrar regiões com a presença de atividades físicas pode contribuir para a elaboração de medidas públicas. Este trabalho aborda o problema da classificação de imagens de diferentes classes esportivas/não-esportivas. Foi realizada a combinação de uma Rede Neural Convolutiva (RNC), classificadores tradicionais e informações geográficas para aplicar o treinamento e testes. Como resultados preliminares, obtivemos alta área sob a curva roc (AUC) em um conjunto de dados de redes sociais. Os resultados experimentais mostram a viabilidade do nosso modelo de proposta.

Palavras-chave: Data mining. Classificação de imagens. Aprendizado de máquina.

1 Introdução

De acordo com Caspersen, Powell & Christenson (1985) a atividade física é definida como qualquer movimento corporal produzido pelos músculos esqueléticos que resulta em gasto energético. Classificada de acordo com a energia gasta: leve, moderada ou intensa. Análises realizadas por Committee et al.(2008) sugerem que a intensidade da atividade física é um fator chave para que os resultados sejam atingidos da melhor forma possível.

Estudos realizados por Hallal et al.(2012) mostram que inatividade física prevalece em 31,1% dos adultos. A estimativa entre jovens de 13-15 anos praticando atividade física de intensidade moderada a vigorosa durante tempo inferior a 60 minutos por dia é de 80,3%. A tendência da inatividade física é aumentar com a idade, como a doença arterial coronariana, diabetes tipo 2, câncer de cólon e mama.

Eliminando a inatividade física 6% a 10% das principais doenças não transmissíveis seriam reduzidas. Consequentemente a expectativa de vida seria aumentada, estimando em média mundial 0.68 anos de vida potencialmente ganhos, apontam estudos realizados por Lee et al.(2012).

Tendo em vista a importância da atividade física para a saúde e as complicações que a inatividade física pode acarretar. Neste trabalho será desenvolvido um modelo computacional capaz de classificar imagens georreferenciadas coletadas por meio das redes sociais.

Foi utilizado uma rede neural convolutiva (RNC) como forma de extrair características das imagens e representá-las em forma de um vetor composto por 2048 *features* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). A classificação das imagens é realizada pelos classificadores



(BOLAND; MURPHY, 2001), que exploram as características das *features* extraídas por meio da RNC para detectar quais grupos compartilham mais semelhanças com uma imagem de entrada.

Atualmente, existem vários métodos que utilizam redes sociais como proposta de seus modelos (KAGAYA; AIZAWA, 2015; FERWERDA; SCHEDL; TKALCIC, 2016; JOSE; HERNANDEZ, 2017). Esses métodos, embora úteis, geralmente não revelam a informação geográfica disponível. Kagaya & Aizawa (2015), por exemplo, investigam um problema de classificação binária comida/não-comida, sem utilizar informações geográficas. Em outro exemplo, Ferwerda, Schedl & Tkalcic (2016) propõe prever a personalidade do usuário por meio das imagens postadas no Instagram. Políticas de saúde pública precisas só são possíveis quando as informações geográficas estão disponíveis e, portanto, a força de qualquer política pública em relação à saúde está estritamente relacionada com as informações geográficas das entradas disponíveis. Portanto, um mapa com a prática esportiva é uma ferramenta importante para diversas ações governamentais de promoção da saúde pública.

2 Trabalhos Relacionados

Este modelo envolve trabalhos em redes neurais convolucionais, classificadores tradicionais, redes sociais, classificação de imagens e localizações geográficas. O modelo proposto realiza a combinação de todos estes temas, os temas abordados são discutidos abaixo.

2.1 Rede Neural Convolutacional

Diversos métodos baseados em redes neurais consistem em camadas de unidades de cálculo interconectadas, as quais estão desencadeando inúmeras aplicações que utilizam métodos supervisionados e não supervisionados (CHERKASSKY; MULIER, 2007). Fatores de ponderação, função de soma, função de transferência, função de aprendizado, função de erro e valor propagado de volta formam um neurônio artificial que é organizado em camadas. Os recursos são apresentados à rede por meio da camada de entrada de dados, que se comunica com uma ou mais camadas ocultas, onde o processamento real é feito por meio de um sistema de conexões ponderadas. As camadas ocultas então se ligam a uma "camada de saída" onde a resposta é gerada. Rede neural convolutacional é uma classe de inspiração biológica que substitui esses três passos por uma única rede neural que é treinada de ponta a ponta a partir de valores de pixel brutos para as saídas do classificador (LECUN et al., 1998; KALCHBRENNER; GREFENSTETTE; BLUNSOM, 2014).

Jose & Hernandez (2017) realiza o mapeamento da atividade de cães e gatos utilizando redes sociais e um conjunto de imagens georreferenciadas em São Francisco. Uma RNC treinada foi utilizada para reconhecer um grande número de classes visuais. Aplicada a mais de um milhão de imagens coletadas no Flickr, a RNC utilizada para detecção de cães e gatos foi o *inception-v3* (SZEGEDY et al., 2016), que se mostrou eficaz com uma taxa de erro de 3.46%.

2.2 Redes Sociais

Serviço que permite aos indivíduos construir perfis públicos ou semipúblicos dentro de um sistema limitado, articular uma lista de outros usuários com os quais eles compartilham uma conexão e uma visão (WASSERMAN; FAUST, 1994). Embora a classificação de imagens relacionadas ao esporte seja conveniente para aplicações reais, o conjunto de trabalhos atuais têm o único propósito de classificar e diferenciar tipos de esportes (BHARATHI; CHAND; RAO, 2011). A geolocalização de práticas esportivas para medidas públicas utilizando a classificação de imagens obtidas por meio de redes sociais não foi explorada até então.

O uso de redes sociais está aumentando e resulta em uma ampla gama de dados que podem ser explorados e estudados. Barbier & Liu (2011) mostram os principais pontos e desafios relacionados à informação por meio de redes sociais e como eles usam métodos de data mining. Os dados disponíveis nas redes sociais podem transcender as fronteiras do mundo físico em escala e extensão que anteriormente não eram possíveis. A mineração de dados pode ajudar pesquisadores e profissionais a superarem desafios ao buscar novas informações que até então estavam escondidas em um grande conjunto de dados.

Kagaya & Aizawa (2015) aborda a classificação das imagens coletadas pelo Instagram, dada uma imagem que o objetivo é descobrir se a imagem contém alimento ou não. Uma abordagem baseada em uma RNC foi realizada por meio de imagens rotuladas como comida/não-comida. Demonstrando a eficácia da combinação de uma rede neural convolucional com classificadores tradicionais

2.3 Classificação de Imagens

A classificação de imagens é uma forma de obter conhecimento de uma grande coleção de imagens (REJANI; SELVI, 2009; BOLAND; MURPHY, 2001; JOSE; HERNANDEZ, 2017). Consiste em realizar o agrupamento de imagens em diferentes classes com características semânticas. Um grupo de imagens rotuladas para extração de características é fornecido em um manual supervisionado, que será usado posteriormente para prever a classe de cada imagem. O sistema de classificação é adaptado com base no objetivo do usuário e inclui balanceamento de dados, pré processamento de dados, extração e seleção de características e escolha de um método de classificação (LU; WENG, 2007).

Em Bharathi, Chand & Rao (2011), o autor propõe um método bayesiano para classificação de imagens esportivas, que combina quatro características diferentes para representar uma imagem, que são: Uma cor; vetor de coerência (CCV), histograma de direção de borda (EDH), vetor de coerência de direção de borda (EDCV) e histograma colorido (CH). Utilizou-se uma base de imagens composta por diversas classes esportivas, nas quais as imagens foram classificadas de acordo com as diferentes características, dividindo-se principalmente em esportes interior e ao ar livre, após as imagens pertencentes à categoria interior foram subdivididas em 3 grupos, tênis de mesa, boxe e sinuca. As imagens pertencentes à categoria ao ar livre foram subdivididas em jogos aquáticos (natação e

windsurf), jogos de neve (imagens de esqui e snowboard) e esportes terrestres (críquete, kabadi e hóquei).

2.4 Classificadores

Máquina de vetores de suporte (SVM). O modelo basicamente constrói um hiperplano em um espaço, o qual pode ser usado para classificação. O mapeamento do hiperplano é realizado por uma função de base radial kernel (RBF), responsável por encontrar uma regra de decisão linear no espaço, buscando uma fronteira de separação ideal (HEARST et al., 1998; CHARFI et al., 2012). A função kernel RBF mapeia não linearmente amostras em um espaço dimensional (HSU et al., 2003).

Rede Neural. Rede Neural é baseada em uma coleção de neurônios artificiais, os quais podem transmitir sinal de um para outro. O neurônio que recebe o sinal processa a informação transmite para os neurônios conectados a ele (HAGAN et al., 1996; YADAV; YADAV; JAIN, 2014). A Rede Neural desenvolve seu próprio conjunto de *features* importantes dos dados processados, sem necessidade de conhecimento prévio sobre os dados.

Regressão Logística. Regressão Logística é um modelo estatístico utilizado para analisar um conjunto de dados. A Regressão Logística tem o objetivo de encontrar o melhor modelo para descrever a relação entre o resultado e um conjunto de variáveis. O coeficiente do modelo é gerado para prever a probabilidade de existir uma característica de interesse (CIOCCA; CUSANO; SCHETTINI, 2015; HARRELL, 2001).

2.5 Conclusão Parcial

Com base nos trabalhos encontrados na literatura foi possível constatar que as redes sociais dispõem de uma gama de informações que se estudadas e exploradas podem ser transformadas em conhecimento.

A partir dos trabalhos referentes à classificação de imagens foi possível perceber que a combinação de uma rede neural convolucional com classificadores tradicionais é uma maneira de otimizar e facilitar a classificação de imagens. Além disso, com a revisão bibliográfica foi possível compreender a importância de informações geográficas. Contudo, ainda não existem estudos que realizam a combinação de todos esses pontos levantados.

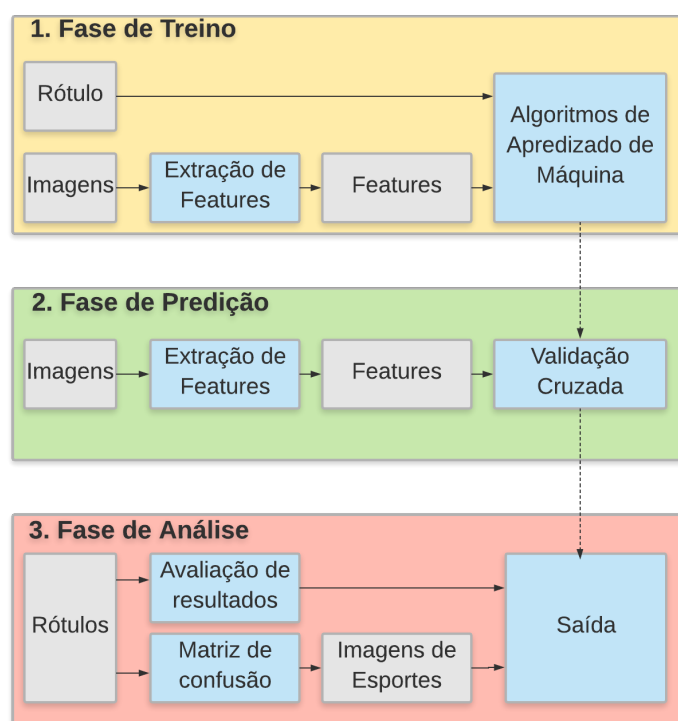
3 Metodologia

O modelo proposto neste trabalho é composto por três etapas principais: (1) etapa de treinamento; (2) etapa de predição e (3) etapa de análise dos resultados. Etapas as quais estão ilustradas na Figura 1 e são descritas nas próximas seções.

O modelo recebe imagens de redes sociais como entrada (imagens de diferentes esportes ou não esporte). Como saída cada imagem possui uma pontuação que indica se a imagem

corresponde a alguma classe de esporte. Possibilitando com as imagens classificadas e georreferenciadas gerar o mapa de esporte.

FIGURA 1 – Diagrama esboçando a metodologia proposta. Cada bloco é detalhado na seção metodologia com nome similar.



Fonte: Autor.

3.1 Fase de treinamento

Na fase de treinamento, a base de dados será construída, será realizada a extração das *features* das imagens e aplicação dos modelos de aprendizado de máquina. As imagens coletadas pelo Flickr correspondem a imagens de esportes. Por outro lado, as imagens coletadas pelo Instagram são de esporte e não esporte. As imagens serão rotuladas especificando a quais classes pertencem. Cada esporte vai possuir uma classe específica. O modelo responsável por extrair as *features* das imagens vai ser o *inception-v3* (SZEGEDY et al., 2016), uma rede neural do Google. Após extrair as *features* três modelos de aprendizado de máquina serão utilizados para treinar e reconhecer padrões presentes nas *features*: Máquina de vetores de suporte (SVM), Rede Neural e Regressão Logística.

3.2 Fase de Predição

Na segunda fase será realizada a predição das imagens. Após a fase de treinamento a capacidade de generalização dos classificadores será calculada por meio do conjunto de imagens coletadas utilizando as *features* extraídas pelo *inception-v3* e validação cruzada, por meio de 10 dobras. A técnica de validação cruzada vai receber como entrada as *features*



extraídas das imagens e os classificadores, gerando os resultados de testes dos classificadores.

3.3 Fase de análise

Na última etapa, os dados resultantes das etapas anteriores serão relacionados de diferentes formas e analisados.

Como saída da validação cruzada e dos classificadores, diferentes rótulos serão determinados, identificando a classe respectiva de cada imagem, não esporte ou esporte. Cada esporte vai possuir sua própria classe.

Comparando os rótulos iniciais com os rótulos gerados pelos classificadores será construída uma matriz de confusão, a qual será responsável por selecionar as imagens iniciais do Instagram que foram rotuladas em diferentes classes de esportes. Os modelos de classificação serão avaliados comparando as taxas de falsos positivo se verdadeiros positivos.

Como saída, nosso modelo apresenta também um mapa contendo a intensidade de diferentes classes de esportes em uma geolocalização.

4 Configuração dos Experimentos

Nesta seção, será detalhado como o experimento foi configurado e quais métricas foram utilizadas para avaliar o mesmo, detalhando a configuração da base de dados, os classificadores, a validação cruzada e como foi realizada a extração de características por meio de uma RNC.

4.1 Base de Dados

Flickr. Este conjunto de dados é construído por meio de imagens esportivas coletadas do Flickr. Este banco de dados tem 487 imagens de 14 classes de esportes. As classes são: Atletismo, basquete, ciclismo, futebol, futsal, handebol, judô, mma, tênis, natação, skate, surf, musculação e vôlei.

Instagram. Este conjunto de dados tem apenas uma classe e foi construído com imagens de cidades com mais de 50 mil habitantes. Contém 26.390 imagens esportivas e não esportivas coletadas de 128 cidades no estado de São Paulo. As Imagens em sua grande maioria são imagens não esportivas.

4.2 Extração de características

As *features* das imagens foram extraídos por meio da RNC do Google, *inception-v3*. Treinada no *ImageNet*, representa as imagens com um vetor numérico com 2048 dimensões.

4.3 Classificadores

Três classificadores diferentes foram utilizados para realizar o experimento.

- **Máquina de vetores de suporte (SVM).** O modelo foi configurado usando a função base radial do kernel (RBF) (HSU et al., 2003).
- **Rede Neural.** O modelo foi configurado usando a função de ativação de camada oculta, ReLu (Função de unidade linear retificada) (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). Para otimizar os pesos, foi utilizado o SGD (Gradiente estocástico de descida) (MAAS; HANNUN; NG, 2013).
- **Regressão Logística.** O modelo utiliza o tipo de regularização L2 com força de custo 1 (SRIVASTAVA et al., 2014).

4.4 Validação Cruzada

Validação cruzada foi utilizada aplicando 10 dobras para comparar e avaliar os classificadores (REFAEILZADEH; TANG; LIU, 2009).

4.5 Métricas de Avaliação

Os métodos utilizados foram avaliados calculando-se a área sob ROC, precisão de classificação, F-1, precisão e revocação de cada método (ZHENG, 2015).

- **Área sobre ROC(AUC).** A curva ROC mostra a sensibilidade do classificador, traçando a taxa de verdadeiros positivos para a taxa de falsos positivos;
- **Precisão de classificação(CA).** É a razão entre o número de previsões corretas e o número total de previsões;
- **Precisão(Precision).** É a proporção de verdadeiros positivos entre instâncias classificadas como positivas;
- **Revocação(Recall).** É a proporção de verdadeiros positivos entre todas as instâncias positivas nos dados.
- **F-1.** É uma média harmônica ponderada de precisão e recordação;

5 Resultados Experimentais

Nesta seção são relatados os resultados e comparações avaliando os métodos utilizados, analisando a matriz de confusão obtida e por fim é apresentado o mapa de esportes gerado.

5.1 Avaliação dos Métodos

Os valores calculados pelas métricas exibidas variam de 1 (perfeito) e pior a 0. Todos os modelos apresentados apresentaram pontuações maiores que 0.9. Estes Resultados mostram

que a combinação da RNC com os classificadores produziu bons resultados. A modelagem do conjunto de dados com imagens esportivas com características descritivas facilita aos classificadores generalizar e distinguir entre imagens esportivas e não esportivas, justificando os bons resultados apresentados pela Tabela 1.

TABELA 1 – Valores obtidos pelos classificadores com base nas métricas apresentadas previamente.

| | AUC | CA | F-1 | PRECISION | RECALL |
|----------------------------|-------|-------|-------|-----------|--------|
| Rede Neural | 0.990 | 0.994 | 0.993 | 0.993 | 0.994 |
| Regressão Logística | 0.994 | 0.994 | 0.994 | 0.993 | 0.994 |
| SVM | 0.996 | 0.993 | 0.991 | 0.991 | 0.993 |

Fonte: Autor.

5.2 Matriz de Confusão

A matriz de confusão resulta na relação entre a classe prevista e a inicial. Desta forma, podemos visualizar as imagens de classe do Instagram que foram previstas como algum tipo de esporte. Os resultados obtidos são mostrados nas Figuras 2 (a), (b) e (c). As imagens destacadas em vermelho são falsos positivos, imagens não esportivas erroneamente classificadas como esporte.

O modelo Regressão Logística retornou 28 imagens classificadas como esportivas. Em 28 imagens 4 são falsos positivos (imagens não esportivas classificadas como esportivas).

O modelo Rede Neural retornou como resultado 34 imagens classificadas como esportivas. Em 34 imagens apenas uma é considerada como falso positivo.

O modelo SVM retornou como resultado 24 imagens classificadas como esportivas, todas classificadas corretamente. É possível observar que existe uma diferença entre a quantidade de imagens obtidas e a precisão de cada modelo.

A Rede Neural foi o modelo capaz de retornar o maior número de imagens e com boa precisão. O aplicativo SVM retornou o menor número de imagens, mas obteve a melhor precisão entre os modelos. Os resultados obtidos por meio da Regressão Logística baseando nas imagens resultantes da matriz de confusão não foram satisfatórios quando comparados aos demais classificadores. Apesar de ter retornado mais imagens que o SVM foi o modelo que mais apresentou falsos positivos.

FIGURA 2 – Saída matriz de confusão. (a) SVM; (b) Rede Neural; (c) Regressão Logística.



Fonte: Autor.

5.3 Mapa de Esportes

O modelo desenvolvido permite criar um mapa de calor relacionando as imagens obtidas pela matriz de confusão com as *geotags*. Com a ajuda de uma API do Google, plotamos os pontos pertencentes a cada *geotag* de imagens esportivas do Instagram no mapa. Calculamos a atividade esportiva de cada cidade normalizando o número de imagens do Instagram classificadas como esporte pelo número total de imagens do Instagram coletadas naquela cidade.

As distribuições de cada modelo são distintas devido aos diferentes resultados obtidos pelos classificadores. Porém apresentam alguma semelhança em relação à distribuição espacial. As distribuições espaciais fazem sentido com base nas cidades consideradas. O nível mais alto de calor é centralizado onde há maior densidade de cidades.

O mapa de esporte Figura 3 (a) mapeia as cidades onde as imagens do Instagram foram coletadas. Os mapas de esporte apresentados nas Figuras 3 (b), (c) e (d) demonstram o mapeamento de imagens georreferenciadas classificadas como esportivas pelos classificadores Regressão Logística, Rede Neural e Máquina de vetores de suporte. Cidades onde não foram encontradas imagens esportivas não foram apontadas pelo mapa esportivo. A intensidade de cada ponto no mapa é proporcional à quantidade de imagens esportivas encontradas naquele ponto, mantendo a proporção de normalização calculada anteriormente.

FIGURA 3 – Mapa de esporte. (a) Cidades consideradas no modelo. (b) Regressão Logística; (c) Rede Neural; (d) SVM.



Fonte: Autor.

6 Conclusão Parcial

A classificação esportiva e não esportiva foi explorada usando a representação da RNC e empregando diferentes abordagens de classificação. Foram relatados altos resultados em duas redes sociais bem conhecidas com representações visuais. Neste trabalho, temos técnicas de representação e classificação para projetar um classificador esportivo e não esportivo robusto e eficiente. Os resultados mostram que a combinação dos classificadores com a RNC extratora de características produz bons resultados e demonstra a eficácia do método. Em outras palavras, o método pode auxiliar na elaboração de políticas públicas referentes à atividade física. A exploração deste modelo diferenciando as classes de esportes será considerada. A quantidade de imagens classificadas como esportivas pelos classificadores se comparadas a amostra total é pequena. Será considerado a coleta de mais imagens buscando o balanceamento da base de dados e evitando que alguma classe seja favorecida.

Referências

- BARBIER, Geoffrey; LIU, Huan. Data mining in social media. In: **Social network data analytics**. [S.l.]: Springer, 2011. p. 327–352.
- BHARATHI, K Jaya; CHAND, P Prem; RAO, SK Mohan. Classification of sports images using naive bayesian classifier. 2011.
- BOLAND, Michael V; MURPHY, Robert F. A neural network classifier capable of recognizing the patterns of all major subcellular structures in fluorescence microscope images of hela cells. **Bioinformatics**, v. 17, n. 12, p. 1213–1223, 2001.
- CASPERSEN, Carl J; POWELL, Kenneth E; CHRISTENSON, Gregory M. Physical Activity, exercise, and physical fitness: definitions and distinctions for health-related research. **Public health reports**, SAGE Publications, v. 100, n. 2, p. 126, 1985.
- CHARFI, Imen; MITERAN, Johel; DUBOIS, Julien; ATRI, Mohamed; TOURKI, Rached. Definition and performance evaluation of a robust svm based fall detection solution. In: **IEEE. Signal Image Technology and Internet Based Systems (SITIS), 2012 Eighth International Conference on**. [S.l.], 2012. p. 218–224.

CHERKASSKY, Vladimir; MULIER, Filip M. **Learning from data: concepts, theory, and methods.** [S.l.]: John Wiley & Sons, 2007.

CIOCCA, Gianluigi; CUSANO, Claudio; SCHETTINI, Raimondo. Image orientation detection using lbp-based features and logistic regression. **Multimedia Tools and Applications**, Springer, v. 74, n. 9, p. 3013–3034, 2015.

COMMITTEE, Physical Activity Guidelines Advisory Et al. Physical activity guidelines advisory committee report, 2008. **Washington, DC: US Department of Health and Human Services**, v. 2008, p. A1–H14, 2008.

FERWERDA, Bruce; SCHEDL, Markus; TKALCIC, Marko. Using instagram picture features to predict users' personality. In: SPRINGER. **International Conference on Multimedia Modeling.** [S.l.], 2016. p. 850–861.

HAGAN, Martin T; DEMUTH, Howard B; BEALE, Mark Het al. **Neural network design.** [S.l.]: Pws Pub. Boston, 1996.

HALLAL, Pedro C; ANDERSEN, Lars Bo; BULL, Fiona C; GUTHOLD, Regina; HASKELL, William; EKELUND, Ulf; GROUP, Lancet Physical Activity Series Working et al. Global physical activity levels: surveillance progress, pitfalls, and prospects. **The Lancet**, Elsevier, v. 380, n. 9838, p. 247–257, 2012.

HARRELL, Frank E. Ordinal logistic regression. In: **Regression modeling strategies.** [S.l.]: Springer, 2001. p. 331–343.

HEARST, Marti A.; DUMAIS, Susan T; OSUNA, Edgar; PLATT, John; SCHOLKOPF, Bernhard. Support vector machines. **IEEE Intelligent Systems and their applications**, IEEE, v. 13, n. 4, p. 18–28, 1998.

HSU, Chih-Wei; CHANG, Chih-Chung; LIN, Chih-Jenet al. A practical guide to support vector classification. Taipei, 2003.

JOSE, Aaron San; HERNANDEZ, Eduardo. City-scale mapping of pets using georeferenced images. **SIGSPATIAL Special**, ACM, v. 8, n. 3, p. 5–6, 2017.

KAGAYA, Hokuto; AIZAWA, Kiyoharu. Highly accurate food/non-food image classification based on a deep convolutional neural network. In: SPRINGER. **International Conference on Image Analysis and Processing.** [S.l.], 2015. p.350–357.

KALCHBRENNER, Nal; GREFFENSTETTE, Edward; BLUNSOM, Phil. A convolutional neural network for modelling sentences. **arXiv preprint arXiv:1404.2188**, 2014.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification



with deep convolutional neural networks. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2012. p. 1097–1105.

LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua; HAFFNER, Patrick. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, IEEE, v. 86, n. 11, p. 2278–2324, 1998.

LEE, I-Min; SHIROMA, Eric J; LOBELO, Felipe; PUSKA, Pekka; BLAIR, Steven N; KATZMARZYK, Peter T; GROUP, Lancet Physical Activity Series Workinget al. Effect Of physical inactivity on major non-communicable diseases worldwide: an analysis of burden of disease and life expectancy. **The lancet**, Elsevier, v. 380, n. 9838, p.219–229, 2012.

LU, Dengsheng; WENG, Qihao. A survey of image classification methods and techniques for improving classification performance. **International journal of Remote sensing**, Taylor & Francis, v. 28, n. 5, p. 823–870, 2007.

MAAS, Andrew L; HANNUN, Awni Y; NG, Andrew Y. Rectifier nonlinearities improve neural network acoustic models. In: **Proc. icml**. [S.l.: s.n.], 2013. v. 30, n. 1, p. 3.

REFAEILZADEH, Payam; TANG, Lei; LIU, Huan. Cross-validation. In: **Encyclopedia Of database systems**. [S.l.]: Springer, 2009. p. 532–538.

REJANI, Y; SELVI, S Thamarai. Early detection of breast cancer using svm classifier technique. **arXiv preprint arXiv:0912.2314**, 2009.

SRIVASTAVA, Nitish; HINTON, Geoffrey; KRIZHEVSKY, Alex; SUTSKEVER, Ilya; SALAKHUTDINOV, Ruslan. Dropout: A simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, JMLR. org, v. 15, n. 1, p.1929–1958, 2014.

SZEGEDY, Christian; VANHOUCKE, Vincent; IOFFE, Sergey; SHLENS, Jon; WOJNA, Zbigniew. Rethinking the inception architecture for computer vision. In: **Proceedings Of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2016. p. 2818–2826.

WASSERMAN, Stanley; FAUST, Katherine. **Social network analysis: Methods and applications**. [S.l.]: Cambridge university press, 1994.

YADAV, Jitender Singh; YADAV, Mohit; JAIN, Ankit. Artificial neural network. **International Journal of Scientific Research and Education**, v. 1, n. 6, p. 108–117, 2014.

ZHENG, Alice. **Evaluating Machine Learning Models A Beginner’s Guide to Key Concepts and Pitfalls**. [S.l.: s.n.], 2015.