

CONSTRUÇÃO DE UM INDICADOR SINTÉTICO DA REDE EMPRESARIAL DA REGIÃO CENTRO-OESTE COM VALIDAÇÃO VIA ALGORITMOS DE APRENDIZADO DE MÁQUINA COM DADOS DE 2021

RESUMO

Este estudo tem como objetivo desenvolver um indicador sintético para analisar a constituição da rede empresarial na região Centro-Oeste. A ferramenta foi elaborada a partir de variáveis econômicas que representam a quantidade de empresas de diferentes setores por mil habitantes em cada cidade. A metodologia envolveu: seleção e tratamento das variáveis, normalização dos componentes, aplicação do *Principal Component Analysis* (PCA), cálculo dos pesos percentuais, normalização do indicador sintético, aplicação do método de classificação *Kmeans* por meio do método do cotovelo, além do uso de *Support Vector Machine* (SVM), matriz de confusão e curva ROC para avaliar a capacidade discriminatória do índice, conferindo-lhe utilidade descritiva e preditiva. Dessa forma, o trabalho visa à contribuição para as políticas de fomento ao desenvolvimento dos setores empresariais. Nesse sentido, o estudo consiste na integração de técnicas estatísticas clássicas (PCA) com métodos de aprendizado de máquina (SVM e ROC), a fim de validar um indicador sintético da rede empresarial. Assim, o indicador pode fornecer subsídios a pesquisadores, gestores públicos e empresas privadas para compreender a dinâmica econômica da rede empresarial da região Centro-Oeste e seu impacto no mercado de trabalho formal.

Palavras-chave: Indicador sintético; Rede empresarial; Região Centro-Oeste; PCA; *K-means*; SVM; Matriz de confusão; Curva ROC.

ABSTRACT

This study aims to develop a synthetic indicator to analyze the constitution of the business network in the Central-West region of Brazil. The tool was designed using economic variables that represent the number of companies from different sectors per thousand inhabitants in each city. The methodology involved:

¹ Mestrando do Programa de Pós-Graduação em Economia Universidade Federal do Mato Grosso (UFMT). E- mail: odairmdjunior@gmail.com

variable selection and treatment, component normalization, application of Principal Component Analysis (PCA), calculation of percentage weights, normalization of the synthetic indicator, application of the K-means classification method through the elbow method, in addition to the use of Support Vector Machine (SVM), confusion matrix, and ROC curve to evaluate the discriminatory capacity of the index, providing it with both descriptive and predictive utility. In this way, the study seeks to contribute to policies aimed at fostering the development of business sectors. Accordingly, the research integrates classical statistical techniques (PCA) with machine learning methods (SVM and ROC) in order to validate a synthetic indicator of the business network. Thus, the indicator may provide support to researchers, policymakers, and private companies to better understand the economic dynamics of the Central-West business network and its impact on the formal labor market. **Keywords:** Synthetic indicator; Business network; Central-West region; PCA; K-means; SVM; Confusion matrix; ROC curve.

1. INTRODUÇÃO

De acordo com Cruz *et al.* (2011), a troca de informações entre empresas funciona como uma externalidade positiva, ampliando os benefícios coletivos. Além disso, as empresas contribuem para a formação do emprego formal, que, segundo Pero e Ramo (1994), é um dos principais indicadores do desenvolvimento socioeconômico de uma região, refletindo a capacidade de geração de renda. Nesse contexto, indicadores constituem medidas quantitativas que operacionalizam conceitos sociais abstratos, servindo tanto a fins acadêmicos quanto programáticos (Mazeto e Santos, 2024). Conforme o Ministério do Planejamento, Orçamento e Gestão (2010), esses instrumentos organizam informações relevantes e comparáveis, subsidiando decisões e políticas públicas voltadas à melhoria das condições de vida da população.

O desenvolvimento envolve ações voltadas ao bem-estar e à melhoria da qualidade de vida, incluindo saúde, educação, moradia e geração de emprego e renda (Freitas, Deponti, Silveira, 2020). A identificação dos resultados dessas ações por meio de medidas de desempenho constitui o principal canal de comunicação com a sociedade e fornece evidências sobre a evolução das medidas políticas (Ministério Do Planejamento, Orçamento E Gestão, 2010). Santos Júnior (2017), argumenta que a política industrial pode ser classificada em horizontais e verticais; as horizontais buscam fomentar a atividade produtiva de forma geral, abrangendo educação, infraestrutura, ciência, tecnologia e inovação, enquanto as verticais são direcionadas a setores ou cadeias produtivas específicas, complementando as horizontais, com caráter transitório e objetivos definidos.

Nas últimas décadas, instituições têm desenvolvido indicadores compostos para analisar nuances da sociedade; contudo, a seleção arbitrária de indicadores individuais, sem considerar suas inter-relações, pode

gerar índices pouco claros ou enganosos. Assim, é fundamental analisar a natureza dos dados antes da construção do indicador, avaliando sua adequação e implicações metodológicas, como ponderação e agregação (OECD/JRC, 2008).

2. REFERENCIAL TEÓRICO

As variáveis foram obtidas de bases oficiais: informações sobre empresas de diferentes setores por meio dos dados da RAIS – Relação Anual de Informações Sociais (Ministério do Trabalho e Emprego, 2021), já a população foi pelo IPEA (Instituto de Pesquisa Econômica Aplicada), enquanto dados sobre estabelecimentos de ensino foram obtidos do INEP– Instituto Nacional de Estudos e Pesquisas Educacionais, 2021. A escolha das variáveis baseou-se em estudos sobre política industrial e estrutura produtiva, destacando a relevância de diferentes setores na dinâmica econômica regional (Santos Júnior, 2017; CRUZ *et al.*, 2011).

A normalização pelo método Min-Max transforma indicadores em valores entre 0 e 1, onde 0 corresponde ao mínimo e 1 ao máximo, garantindo comparabilidade (Nardo *et al.*, 2005). Apesar de simples, o método pode ser sensível a *outliers* (OECD/JRC, 2008). Assim, Optou-se pela normalização Min-Max em detrimento de outros métodos, como padronização z-score, por se tratar do procedimento adotado no Caderno Metodológico do ICQV-MT (SEPLAG, 2022), o que assegura comparabilidade com outros estudos regionais. Para Medeiros e Figueiredo (2024), a agregação linear ponderada foi escolhida por seguir a mesma base metodológica, garantindo consistência com indicadores já consolidados, enquanto

Segundo Felipe *et al.* (2021), com o uso do *Principal Component Analysis* (PCA) identifica combinações lineares das variáveis originais que maximizam a variância, sendo não correlacionadas, obtidas por autovalores/autovetores ou decomposição em valores singulares (SVD). O PCA quantifica a variância explicada e analisa *loadings*, facilitando a interpretação, ou seja, permite de reduzir a dimensionalidade, extraíndo fatores não correlacionados e permitindo a atribuição de pesos objetivos às variáveis. (Jolliffe & Cadima, 2016). A agregação linear é adequada quando indicadores possuem a mesma unidade, pressupondo compensabilidade plena (NARDO *et al.*, 2005). Já o uso do *k-means* fatorial integra PCA com *k-means*, minimizando distâncias *intra-cluster* e maximizando *inter-clusters* (Aggarwal & Reddy, 2014). A classificação em grupos considera variações em critérios de decisão (Swets, 1988).

A literatura em políticas públicas ressalta a relevância dos indicadores sintéticos na formulação de estratégias de desenvolvimento regional (Mazeto e Santos, 2024). Ainda assim, a combinação desses indicadores com técnicas de aprendizado de máquina, como PCA, *k-means* e SVM, abre novas possibilidades, permitindo não apenas descrever realidades, mas também antecipar padrões e identificar grupos homogêneos, ampliando o alcance e a aplicabilidade das políticas. Dessa forma, o uso do *Support Vector Machine* (SVM) busca encontrar hiperplanos de separação com “margem larga”, garantindo que os

exemplos de cada classe fiquem não apenas do lado correto, mas também afastados da fronteira de decisão dele. (Shalev-Shwartz & Ben-David, 2014). Em conjunto com a análise ROC, esse modelo permite avaliar os classificadores de múltiplas classes, com a área sob a curva (AUC) indicando qualidade do diagnóstico (Matsubara, 2008; Hamilton, 2000). E com a matriz de confusão analisa desempenho, considerando sensibilidade e especificidade (Hempel *et al.*, 2012).

3. METODOLOGIA

Foram analisadas 22 variáveis refletindo a estrutura produtiva e social: indústria extrativa (x1), produção de minerais não metálicos (x2), eletricidade e comunicação (x3), material de transporte (x4), madeira e mobiliário (x5), papel e gráfica (x6), borracha, fumo e couros (x7), alimentos e bebidas (x8), construção civil (x9), instituições financeiras (x10), administração técnica e profissional (x11), transporte e comunicações (x12), alojamento comunitário (x13), serviços médicos e odontológicos (x14), agricultura (x15), estabelecimentos de ensino básico (x16), fundamental (x17), médio (x18), especial (x19), profissional (x20), quantidade total de indústrias (x21) e comércio (x22). Dados foram obtidos da RAIS e INEP. Tratamento das variáveis seguiu a metodologia descrita no Caderno Metodológico do ICQV-MT: Índice de Condição e Qualidade de Vida de Mato Grosso (SEPLAG, 2022). Inicialmente, as variáveis foram ajustadas pela população, dividindo-se cada valor pelo número de habitantes e multiplicando-se por mil, a fim de expressá-las em taxas por mil habitantes. Em seguida, aplicou-se a transformação pela raiz quadrada e, para as variáveis cuja assimetria excedeu 1, utilizou-se a transformação logarítmica. Após esse processo, todas as variáveis foram normalizadas pelo método Min-Max, conforme orientações do *Handbook on Constructing Composite Indicators* (OECD; JRC, 2008). De acordo com a OECD e JRC (2008), a normalização descreve para cada variável “ x'_{qc} ”, onde “ q ” representa cada cidade e o “ c ” para cada variável considerada, assim, os valores serão normalizados por meio da seguinte transformação:

$$I_{qc}^t = \frac{x'_{qc} - \min_c(x'_q{}^t)}{\max_c(x'_q{}^t) - \min_c(x'_q{}^t)}$$

Onde “ $\max_c(x'_q{}^t)$ e $\min_c(x'_q{}^t)$ ” são, respectivamente, os valores mínimos e máximos de “ x'_{qc} ”. Dessa forma, os indicadores normalizados I_{qc}^t terão valores entre 0 (pior desempenho, ou “*laggard*”, quando “ x'_{qc} ” = “ $\min_c(x'_q{}^t)$ ”) e 1 (melhor desempenho, ou “*leader*”,

quando “ x'_{qc} ” = “ $\max_c(x'_q{}^t)$ ”).

Após isso, foi aplicado o PCA nas variáveis tratadas para reduzir a dimensionalidade, transformando em variáveis originais (Medeiros e Figueiredo, 2024). Segundo a OECD e JRC (2008), a *Principal Component Analysis* (PCA) tem como objetivo reduzir a dimensionalidade de um conjunto de dados. Posteriormente, os pesos foram somados em módulo e em seguida transformados em percentuais (Medeiros & Figueiredo, 2024). Após isso, agregação linear ponderada foi aplicada (SEPLAG, 2022):

$$CI_c = \sum_{i=1}^m w_i z_{c,i}$$

Onde CI_c é o índice, $z_{c,i}$ são subindicadores normalizados, e w_i são pesos. Em seguida, o índice sintético foi normalizado para garantir o intervalo, de 0 e 1 (OECD, JRC, 2008). Na sequência, foi aplicado o *k-means* para fazer o recorte das classes, (Matte e Nicoletti, 2019; Faccamp, 2019).

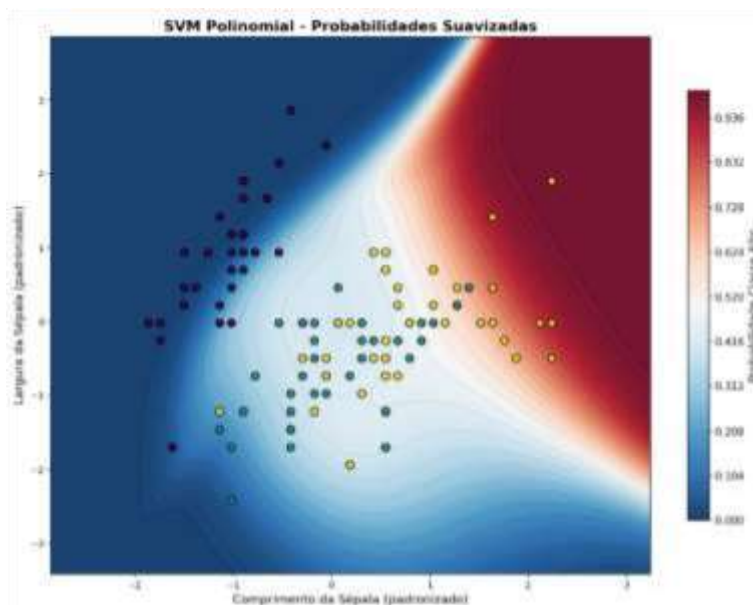
Para verificar a validação do indicador sintético, foram usados o método de Máquinas de Vetores de Suporte (SVM) com o *kernel* Polinomial. Segundo Shalev-Shwartz e Ben-David (2014), o conceito de *kernel* parte da ideia de um mapeamento implícito para um espaço de características de maior dimensão, permitindo que relações não lineares no espaço original possam ser linearmente separáveis nesse novo espaço, assim é possível visualizar as regiões de *clusters* que foram identificadas junto com o resultado de treinamento. Em conjunto, o uso da matriz de confusão visou quantificar os acertos e erros do classificador, sendo uma ferramenta útil para visualizar e avaliar seu desempenho em problemas com três ou mais classes. Na interpretação dos dados, a acurácia mostra o percentual de acertos do modelo, embora possa ser enganosa em conjuntos desbalanceados. A precisão indica a confiabilidade das previsões positivas, a sensibilidade mede a capacidade de identificar corretamente todos os casos positivos, e a especificidade avalia a identificação correta dos casos negativo (Varoquaux e Colliot, 2023). Por fim, o uso da curva ROC (Receiver/Relative Operating Characteristic) representando a relação entre verdadeiros positivos e falsos positivos em diferentes critérios de decisão. Sua principal métrica é a área sob a curva (AUC), que varia de 0,50 a 1,0: valores próximos de 0,50 indicam ausência de discriminação (resultado equivalente ao acaso) e valor igual a 1,0 indica discriminação perfeita, assim, Ac_a mais próximo de 1 apresenta um bom desempenho (SWETS, 1988). A área sob a curva ROC (*Area Under the Curve – AUC*) pode ser utilizada como medida de acurácia, refletindo a capacidade do classificador de distinguir entre classes, independentemente da distribuição de custos e classes. (Swets, 1988; Provost & Fawcett, 1997, apud Hamilton, 2009).

Em síntese, o encadeamento metodológico seguiu as seguintes etapas: (i) tratamento e normalização das variáveis, (ii) redução da dimensionalidade via PCA e cálculo dos pesos, (iii) construção do indicador sintético por agregação linear ponderada, (iv) classificação dos municípios em grupos por meio do *k-means*, e (v) validação da consistência do indicador com técnicas de aprendizado de máquina (SVM, matriz de confusão e curva ROC). Essa sequência assegura que o índice não apenas sintetize informações relevantes, mas também apresente utilidade descritiva e preditiva. Ainda, esse trabalho contou com o apoio de ferramentas de inteligência artificial generativa (ChatGPT, DeepSeek, Gemini, Grok) no processo de revisão e estruturação textual, tais ferramentas não forma usadas nas análises estatísticas e nos resultados obtidos.

4. RESULTADOS E DISCUSSÃO

Conforme na Figura 1, observa-se que os resultados da classificação realizada pelo modelo SVM com *kernel* polinomial, considerando as três categorias de interesse: baixo, médio e alto. Na imagem, observa-se a fronteira de decisão do classificador, representada pelas regiões de probabilidade suavizada. Cada ponto corresponde a uma observação, e as áreas coloridas ilustram a probabilidade de pertencimento a cada classe. Nota-se que as classes *baixo* apresenta uma região bem definida, enquanto a classe *médio e alto* mostra maior sobreposição com a classe *médio*, o que indica a dificuldade do modelo em discriminar esses grupos.

Figura 1: Resultados da classificação SVM com kernel polinomial



Fonte: elaboração do autor.

Na tabela 1, observa-se que a classe *baixo* apresentou desempenho considerado perfeito, enquanto a classe *médio* teve uma sensibilidade considerável (0,85) e não possui uma precisão, e ainda, a classe *alto*

teve o menor índice referente a sensibilidade (0,31) com F1-Score de 0,42, indicando confusão com a classe médio. Ao considerar o modelo geral, obteve uma acurácia global de 0,76.

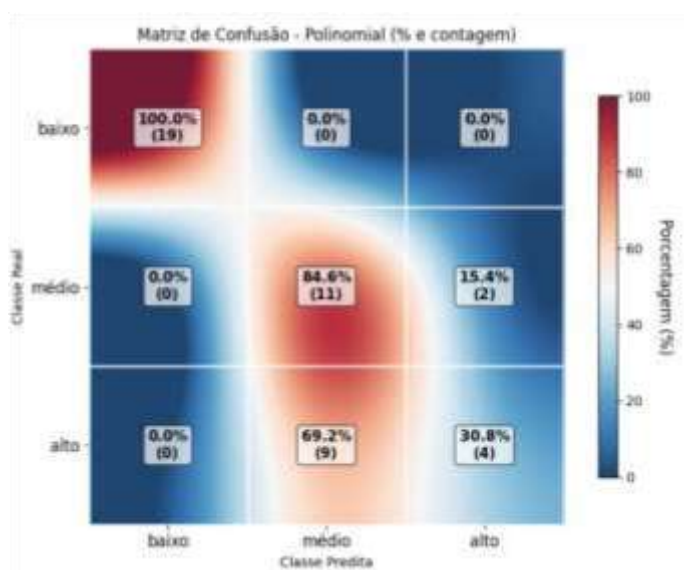
Tabela 1: Métricas para SVM com *Kernel* Polinomial

Classe	Precisão	Sensibilidade	F1-Score	Suporte
Baixo	1,00	1,00	1,00	19
Médio	0,55	0,85	0,67	13
Alto	0,67	0,31	0,42	13
Acurácia			0,76	45
Média macro	0,74	0,72	0,70	45
Média ponderada	0,77	0,76	0,74	45

Fonte: elaboração do autor.

A matriz de confusão apresenta a proporção e a contagem de acertos e erros por classe, a classe *baixo* obteve 100% de acerto, sem erros de classificação. A classe *médio* alcançou 84,6% de acertos, mas apresentou 15,4% de confusão com a classe *alto*. Já a classe *alto* apresentou apenas 30,8% de acertos, sendo que 69,2% dos casos foram incorretamente atribuídos à classe *médio*. Os resultados indicam que o padrão observado na tabela de métricas possui uma dificuldade na distinção entre médio e alto.

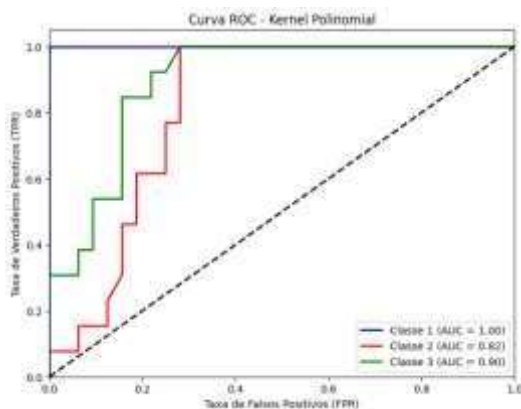
Figura 2- Matriz de Confusão



Fonte: elaboração do autor.

Por fim, a Figura 3, no gráfico da Curva ROC (inferior direito), apresenta a performance do modelo em um cenário multiclasse pelo método *one-vs-rest*. Cada curva representa uma das classes, e a área sob a curva (AUC) variou de 0,82 a 1,00, indicando boa capacidade de discriminação do classificador. Entretanto, assim como nos outros modelos, a classificação do grupo denominado 'baixo' foi satisfatória, enquanto os dois grupos restantes apresentaram maior dificuldade de discriminação.

Figura 3- Curva ROC



Fonte: elaboração do autor.

Os resultados revelam que o indicador discrimina de forma robusta os municípios com baixo dinamismo empresarial, o que pode auxiliar gestores na priorização de políticas de estímulo econômico. Contudo, a sobreposição entre as classes médio e alto indica que, na prática, a diferenciação entre cidades mais desenvolvidas é menos clara, dessa forma, o indicador deve ser aprimorado com novas metodologias ou trabalhar com apenas duas classes das quais seria baixa estrutura empresarial e alta estrutura empresarial.

4. CONCLUSÕES

O presente estudo desenvolveu e avaliou o indicador sintético da rede empresarial da região Centro-Oeste, integrando técnicas estatísticas tradicionais (PCA) e métodos de aprendizado de máquina (SVM, matriz de confusão e curva ROC). Os resultados demonstraram que o índice possui boa capacidade discriminatória, em especial para identificar municípios com baixo dinamismo empresarial, alcançando acurácia geral de 0,76.

A principal contribuição do trabalho reside na incorporação de ferramentas de validação preditiva, aspecto ainda pouco explorado em estudos sobre indicadores regionais no Brasil. Essa abordagem amplia a utilidade prática do indicador, permitindo que gestores públicos e agentes privados não apenas descrevam a realidade, mas também antecipem tendências de desenvolvimento econômico.

Ressalta-se que os dados utilizados referem-se ao ano de 2021, o que representa uma fotografia específica do período analisado. Nesse sentido, a replicação futura da pesquisa com dados mais recentes permitirá não apenas atualizar o diagnóstico da rede empresarial da região, mas também aprimorar a robustez do indicador.

O estudo indica a hipótese de que o PCA integrado ao SVM pode gerar um indicador com uma capacidade discriminatória, nesse caso, por meio do SVM, da Matriz confusão e do ROC, é demonstrado que ao classificar grupos a médio e altos, não possuem uma boa eficiência na discriminação entre esses grupos, o que indica que são parecidos. Ainda, a dificuldade em diferenciar as classes médio e alto, indica que essas variáveis quantitativas de estrutura produtiva não são suficientes para capturar dimensões mais sofisticadas da rede empresarial.

Do ponto de vista prático, os resultados oferecem subsídios importantes para gestores públicos. A distinção entre municípios com baixo dinamismo empresarial podem adquirir políticas de estímulo, como capacitação empreendedora e incentivos fiscais a esse grupo. Por outro lado, a dificuldade em diferenciar os níveis médio e alto indica que o estudo deve ser aprimorado na identificação desses grupos. Portanto, pesquisas futuras podem incorporar outras variáveis, além de testar diferentes *kernels* no SVM, ampliando a precisão do modelo. Esperase, assim, contribuir para o aprimoramento de indicadores regionais e subsidiar políticas públicas mais eficazes no fortalecimento da rede empresarial brasileira.

REFERÊNCIAS BIBLIOGRÁFICAS

AGGARWAL, Charu C.; REDDY, Chandan K. (Ed.). Data Clustering: Algorithms and Applications. Boca Raton: CRC Press, 2013.

CRUZ, Bruno de Oliveira Organizador *et al.* Economia regional e urbana: teorias e métodos com ênfase no Brasil. 2011.

DE OLIVEIRA, Fábio Manuel Rodrigues. Estimação paramétrica e não-paramétrica da curva ROC. 2012. Dissertação (Mestrado) - Universidade de Coimbra, Coimbra, Portugal, 2012.

DUARTE, Miqueias Lima; DA SILVA, Tatiana Acácio. Avaliação do desempenho de três algoritmos na classificação de uso do solo a partir de geotecnologias gratuitas. *Revista de Estudos Ambientais*, v. 21, n. 1, p. 6-16, 2019.

FREITAS, Tanise Dias; DEPONTI, Cidonea Machado; SILVEIRA, Rogério Leandro Lima. (Orgs.). *Políticas Públicas e Desenvolvimento Regional: Atores e Estratégias em Regiões do Brasil*. São Carlos: Pedro & João Editores, 2020.

GEWERS, Felipe L. *et al.* Principal component analysis: A natural approach to data exploration. *ACM Computing Surveys (CSUR)*, v. 54, n. 4, p. 1-34, 2021.

HAMILTON, Howard *et al.* *Computer Science 831: Knowledge discovery in databases*. www2.cs.uregina.ca, 2000.

HEMPEL, Susanne *et al.* *Machine learning methods in systematic reviews: identifying quality improvement intervention evaluations*. 2012.

INSTITUTO NACIONAL DE ESTUDOS E PESQUISAS EDUCACIONAIS – INEP. *Dados educacionais*. Brasília: INEP, 2021.

JOLLIFFE, Ian T.; CADIMA, Jorge. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A*, v. 374, n. 2065, p. 20150202, 2016.

MATTE, Marcelo Kuchar; DO CARMO NICOLETTI, Maria. *Revisão de Estratégias para a Aceleração do Algoritmo k-Means*. In: *Anais do Workshop em Computação da FACCAMP*. 2019. p. 1-6.

MATSUBARA, Edson Takashi. *Relações entre Ranking, Análise ROC e Calibração em Aprendizado de Máquina*. 2008. Tese (Doutorado) — Instituto de Ciências Matemáticas e Computação, USP, São Carlos, 2008.

MAZETO, Rafael Albertoni; SANTOS, Harlon R. R. *Importância dos indicadores socioeconômicos nas políticas públicas: o índice de condição e qualidade de vida no Mato Grosso (ICQV-MT)*. In: OLIVEIRA, A. V. de et al. (Org.). *Políticas públicas regionais: o município*. Curitiba: CRV, 2024. v.3, p.25-40.

MEDEIROS, Hugo A. V.; FIGUEIREDO FILHO, D. B.; LIMA, M. T. A.; LUCENA, P. M. P.; SOUZA, L. S. de O. *Construção de indicadores sintéticos para tomada de decisão em governo: um tutorial*. In: *CONGESP*, 16., 2023, Natal. *Anais*. Natal: Governo do Estado do RN, 2023.

MINISTÉRIO DO PLANEJAMENTO, ORÇAMENTO E GESTÃO. *Secretaria de Planejamento e Investimentos Estratégicos. Indicadores de Programa: guia metodológico*. Brasília: Ministério do Planejamento, 2010.

MINISTÉRIO DO TRABALHO E EMPREGO. *Relação Anual de Informações Sociais — RAIS*. Brasília, 2021.

NARDO, M. *et al.* *Tools for composite indicators building*. European Commission, Ispra, v. 15, n. 1, p. 19-20, 2005.

OECD; JRC. *Handbook on Constructing Composite Indicators: Methodology and User Guide*. 2008.

PERO, Valério Lúcia; RAMO, Lauro Roberto Albrecht. Absorção de trabalhadores no setor formal e melhoria da qualidade do emprego. Brasília: IPEA, 1994.

PLATT, J. C. *et al.* Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. *Advances in Large Margin Classifiers*, v.10, p.61-74, 1999.

SANTOS JÚNIOR, Walter L. dos *et al.* Ensaio sobre indústria e política industrial. 2019.

SEPLAG (SECRETARIA DE ESTADO DE PLANEJAMENTO E GESTÃO). Caderno metodológico ICQV-MT: Índice de Condição e Qualidade de Vida de Mato Grosso. Cuiabá: SEPLAG, 2022.

SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. *Understanding machine learning: From theory to algorithms*. Cambridge: Cambridge University Press, 2014.

STEINWART, Ingo; SCOVEL, Clint. *Fast rates for support vector machines using Gaussian kernels*. 2007.

SWETS, John A. Measuring the accuracy of diagnostic systems. *Science*, v. 240, n. 4857, p. 1285-1293, 1988.

VAROQUAUX, Gaël; COLLIOT, Olivier. Evaluating machine learning models and their diagnostic value. In: *Machine Learning for Brain Disorders*, p. 601-630, 2023.

VILELA JUNIOR, G. B. *et al.* Determinação das métricas usuais a partir da matriz de confusão de classificadores multiclases em algoritmos inteligentes nas ciências do movimento humano. *Revista CPAQV*, v.14, n.2, 2022.