

Influência de fatores socioeconómicos no sistema de Ensino Português

Paulo Pombinho¹, Luís Cavique², Luís Correia³

¹ Universidade Aberta, Lisboa, Portugal, paulo.matos@uab.pt

² Universidade Aberta, Lisboa, Portugal, luis.cavique@uab.pt

³ Faculdade de Ciências da Universidade de Lisboa, Portugal, luis.correia@ciencias.ulisboa.pt

Resumo

O presente artigo estuda a influência dos fatores socioeconómicos dos diferentes municípios no sucesso educacional dos estudantes. Para verificar a existência de fatores relevantes para o percurso académico dos estudantes, foram obtidos datasets com descritores socioeconómicos por município, médias das notas dos exames nacionais e as taxas de sucesso dos alunos. Estes datasets foram submetidos a uma técnica de K-nearest neighbours para permitir encontrar valores de atributos em municípios com valores em falta. Foram, de seguida, aplicados algoritmos de classificação, através de árvores de decisão e regressão, que permitiram analisar quais os atributos socioeconómicos que tinham, potencialmente, maior relação com o sucesso escolar. O trabalho efetuado permite identificar alguns fatores como alvos de potenciais estudos futuros sem, no entanto, se verificar correlações fortes com nenhum atributo socioeconómico.

Palavras-chave: sucesso educativo, dados socioeconómicos, classificação, prospeção de dados, k-nearest neighbours, árvores de decisão

Title: Influence of socio-economic factors on the Portuguese education system

Abstract: This paper studies the influence of the socio-economic factors of different municipalities on the educational success of students. To verify the existence of relevant factors to the academic course of the students, datasets were obtained with socio-economic descriptors by municipality, average grades of national exams and success rates of students. These datasets were submitted to a K-nearest neighbours technique to allow finding attributes in municipalities with missing values. Classification algorithms were then applied through decision and regression trees, which allowed analyzing which socio-economic attributes were potentially more related to school success. The work performed allowed identifying some factors as targets of potential future studies without, however, verifying strong correlations with any socio-economic attribute.

Keywords: educational success, socio-economic data, classification, data mining, k-nearest neighbours, decision trees

1. Introdução

A educação abrange um conjunto de níveis, desde o jardim de infância, ensino básico e secundário, até ao ensino superior. O sector da educação pode ser visto como uma série de componentes onde cada aluno segue um caminho que vai ao encontro das suas próprias aspirações (Tavares, 1995).

Existem muitos exemplos da aplicação de modelos matemáticos ao planeamento da educação desde o final dos anos 60 (Lovell 1971).

Na ciência da educação dois KPI (indicadores-chave de desempenho) são geralmente estabelecidos no fluxo de estudantes: abandono e insucesso (ou retenção) (Junior et al. 2012). O conhecimento e previsão do abandono e retenção no fluxo de estudantes é muito relevante, uma vez que estes KPI influenciam diretamente o desempenho do sistema educativo.

O projeto ModEst, teve como objetivo estudar o sistema de ensino português, através da análise e representação do fluxo de estudantes. Esta análise foi permitida através do acesso a dados, disponibilizados pela Direção-Geral de Estatísticas da Educação e Ciência (DGEEC), compreendendo os anos letivos desde 2008/2009 até 2019/2020 (12 anos letivos). Os dados disponibilizados incluem informação que engloba todos os ciclos de ensino, desde o pré-escolar até ao ensino superior.

No decorrer do projeto, foi feita uma análise aprofundada do sistema de ensino e foram criados e executados procedimentos ETL (Extract Transform Load) que permitiram extrair e otimizar os dados disponibilizados para a sua utilização posterior, tendo este sido um processo iterativo que permitiu identificar e em alguns casos resolver problemas existentes com os dados (Cavique, 2020).

Através dos dados obtidos foi possível observar algumas indicações da existência da influência possíveis fatores socioeconómicos no sucesso / insucesso dos alunos. Neste artigo será apresentada a análise efetuada, com o recurso a árvores de decisão e regressão de forma a tentar perceber quais os indicadores que poderiam ter uma maior influência.

Na secção 2 são introduzidos conceitos relevantes para compreender os dados existentes e a análise efetuada. Na secção 3 é descrita a avaliação preliminar das taxas de sucesso por município. Na secção 4 é descrito o dataset e a forma como este foi obtido e, na secção 5, é apresentada a utilização de uma adaptação do algoritmo K-Nearest Neighbours que permitiu corrigir a ausência de alguns dados do dataset obtido. Na secção 6 é apresentado o trabalho respeitante à criação das árvores de decisão e de regressão e na secção 7 e 8 são apresentados os resultados obtidos e as conclusões finais, respetivamente.

2. Definições

Para uma melhor compreensão do trabalho executado serão de seguida apresentadas algumas definições utilizadas no decorrer do projeto ModEst, e descritas em maior detalhe em (Cavique, 2020).

A tabela de fatos do ModEst (Tabela 1) contém um conjunto de atributos, dos quais se destacam:

Tabela 1 – Principais atributos utilizados no projeto ModEst.

Atributo	Contexto		Exemplo
	EBS	Superior	
Ano letivo	x	x	2008/2009
Ano curricular	x	x	10º ano
Idade	x	x	15
Género	x	x	Feminino
Informação Geográfica (NUTS ¹ II / III)	x	x	Norte / Ave
Nível de Ensino	x		Ensino Básico
Nível de Formação		x	Mestrado Integrado
Modalidade	x		Ensino Regular
CNAEF		x	Artes e Humanidades
Natureza	x	x	Público
Tipo de Ensino		x	Universitário
Acontecimento_DGEEC	x		Transição/conclusão
Habilitações	x	x	Licenciatura
Situação de Emprego	x	x	Desempregado

Utilizando os dados contidos na base de dados disponibilizada pela DGEEC, é possível definir um estado associado ao ano curricular em que o aluno se inscreve, em cada ano letivo, com informação adicional acerca dos restantes atributos referidos na tabela anterior.

Para melhor representar as mudanças entre estados, optou-se por definir um novo tipo de acontecimento (acontecimento_M) com uma maior granularidade relativa ao acontecimento contido na base de dados da DGEEC (acontecimento_DGEEC).

Este acontecimento contém quatro tipos de mudança de estados (Figura 1):

- Transição – Um aluno transita de ano quando no ano letivo seguinte está num ano curricular superior;
- Retenção – Um aluno fica retido se, no ano letivo seguinte está no mesmo ano curricular em que estava;
- Ingresso – Um aluno ingressa se não existe informação sobre ele no ano letivo anterior;
- Abandono – um aluno abandona caso não exista informação sobre ele no ano letivo seguinte.

¹ Nomenclatura das Unidades Territoriais para Fins Estatísticos

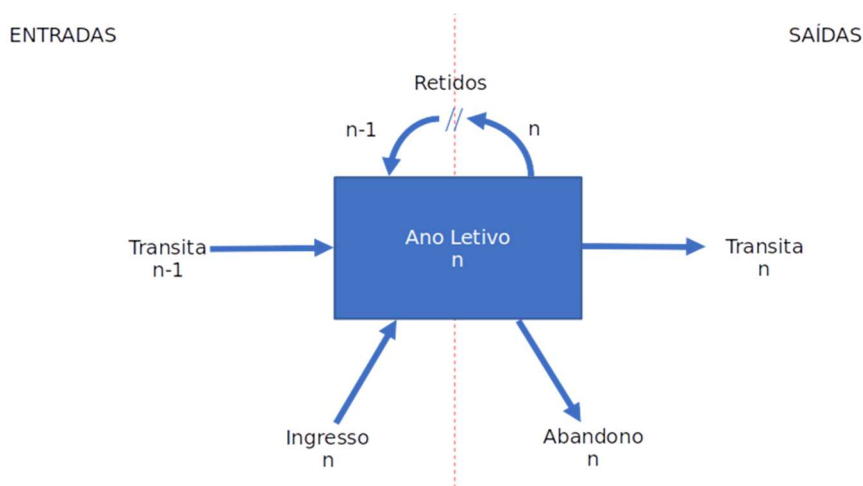


Figura 1 - Representação de um estado com possíveis acontecimentos (entrada e saída).

Para utilizar os dados existentes na BD, foi efetuado um processo de ETL (extract, transform, load) através do qual é possível tratar os dados solucionando alguns problemas existentes na base de dados. Após a fase de limpeza dos dados, estes são extraídos como dados agregados para utilização externa nas etapas de análise.

Existem três classes de ficheiro de dados que são extraídos da base de dados do ModEst: ficheiros de acontecimentos, mobilidades e percursos.

Os ficheiros de acontecimentos contêm uma vista agregada, com inscrições dos alunos e permitem obter informação sobre as inscrições dos alunos e respetivos acontecimento, nomeadamente: ingressos, abandonos, retenções ou transições. Esta informação é combinada com alguns outros atributos como por exemplo, idade, género, modalidade, natureza e informação geográfica, para permitir análises mais detalhas e também a possibilidade de filtrar os dados com esses atributos. Na tabela seguinte (tabela 2) é apresentado um exemplo do tipo de dados obtidos. Este tipo de ficheiros é útil para analisar e visualizar informação anual sobre o sistema de ensino, bem como serve de base ao cálculo de probabilidades utilizado na modelação do sistema, descrita na secção 5. Importa referir que todos os ficheiros contêm informação agregada, existindo uma coluna “contador” através da qual é possível perceber quantas entradas, da base de dados, partilham os mesmos atributos, estando assim agrupadas.

Tabela 2 – Extrato do ficheiro com informação sobre inscrições de alunos.

ano_letivo	ano_curricular	idade	genero	NUTSII	NUTSIII	NIVEL_ENSINO	MODALIDADE	NATUREZA	ACONTECIMENTO_DGEEC	ingresso	acontecimento_M	contador
2018	7	13	F	Algarve	Algarve	Ensino básico	Ensino regular	Público	Transição/conclusão	não	transita	432
2016	8	14	M	Alentejo	Baixo Alentejo	Ensino básico	Ensino regular	Público	Transição/conclusão	não	transita	84
2017	10	15	F	Norte	Cávado	Ensino secundário	Ensino regular	Público	Retenção e desistência	não	retido	51
2011	5	11	M	Centro	Médio Tejo	Ensino básico	Ensino regular	Público	Transição/conclusão	não	transita	172
2017	10	15	F	Centro	Região de Aveiro	Ensino secundário	Ensino regular	Público	Retenção e desistência	não	retido	51
2014	10	15	M	Centro	Oeste	Ensino secundário	Cursos profissionais	Privado	Transição/conclusão	não	transita	63
2011	9	15	F	Centro	Região de Aveiro	Ensino básico	Cursos CEF	Público	Transição/conclusão	não	transita	56
2018	7	12	M	Centro	Oeste	Ensino básico	Ensino regular	Privado	Transição/conclusão	não	transita	251
2013	5	10	M	Norte	Ave	Ensino básico	Ensino regular	Público	Transição/conclusão	não	transita	1495
2013	2	8	M	Norte	Tâmega e Sousa	Ensino básico	Ensino regular	Público	Transição/conclusão	não	transita	255

A obtenção dos dados descritos acima é feita para o ensino básico e secundário e também para o ensino superior, originando dois conjuntos de ficheiros. Por outro lado, devido às diferentes características do ensino regular quando comparado com outros tipos de modalidades de ensino, optou-se por ter um conjunto de dados em que se separa o ensino

regular das restantes modalidades e ainda um conjunto que representa a totalidade das modalidades de ensino.

3. Taxas de Sucesso Escolar por Município

No decorrer do projeto, foram analisadas as correlações entre as taxas de sucesso (transição vs. retenções e abandonos) de acordo com a zona geográfica dos alunos.

Uma análise da visualização de quais as NUTS III que têm valores de sucesso acima da média nacional (representadas a verde) em comparação com os locais que estão abaixo da média (pintados em tons de vermelho) levantam a hipótese de existência de algum fator relacionado com fatores socioeconómicos que possam influenciar o sucesso em cada zona. Na figura 2 é apresentada uma visualização da variação da taxa de sucesso por NUTS III (esquerda) e por concelho (direita).

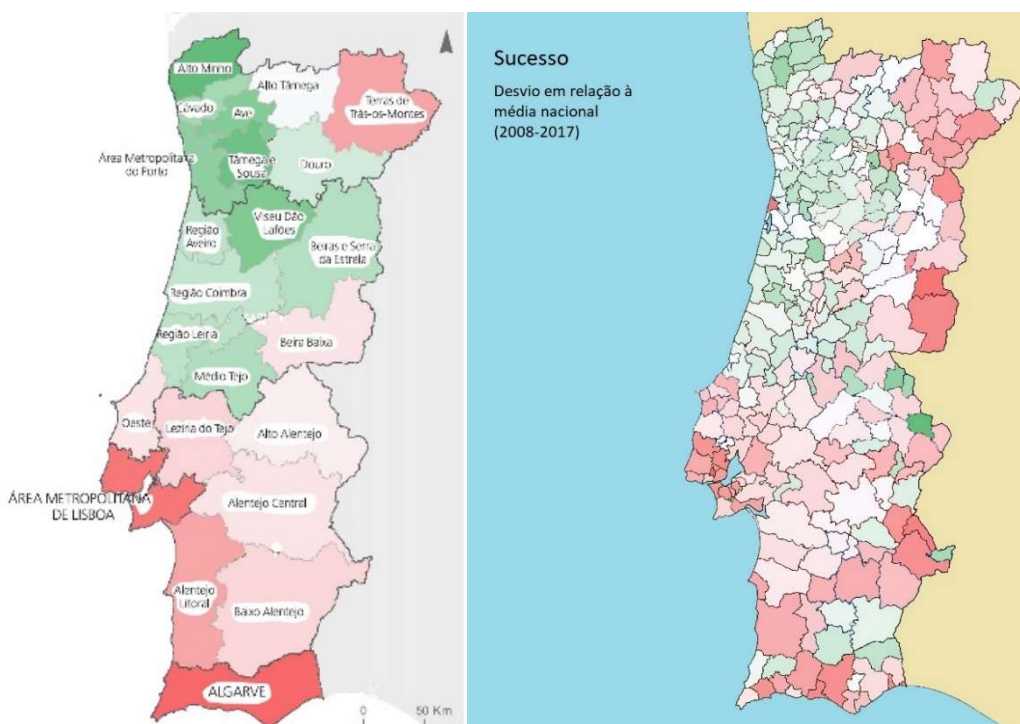


Figura 2 – Desvio da taxa de sucesso em relação à média nacional.

Para avaliar se existe realmente uma relação entre algum fator territorial que possa ter influência no sucesso dos alunos, optou-se por relacionar a informação do sucesso, obtida através das bases de dados da DGEEC, com uma tabela de informação socioeconómica por municípios, obtidas através da Pordata. Para poder fazer o cruzamento dos dados de forma automática, foram utilizadas técnicas de criação de árvore de decisão e regressão, que geram árvores em que, em cada nó destas, se pretende obter a maior informação possível. Nas seções seguintes irá ser descrito o processo de tratamento dos dados socioeconómicos bem como a geração das árvores.

4. Obtenção dos Datasets

Para verificar a existência de correlações foi necessário obter o conjunto de dados socioeconómicos, bem como outro dataset com o valor alvo a ser estudado, que neste caso correspondia ao sucesso dos alunos.

Para poder fazer uma avaliação por município foram extraídas um conjunto de séries de dados através da Pordata, que abrangiam séries relacionados com os seguintes tópicos:

- Ambiente
- Ciência
- Cultura
- Educação
- Emprego
- Empresas
- Turismo

Após a obtenção dos ficheiros individuais, estes foram integrados numa única tabela, em que se relacionava cada um dos municípios com os seus dados socioeconómicos, perfazendo um total de 244 municípios, cada um com 913 atributos. No caso de alguns atributos, foi feito ainda um processamento para obter valores per capita, do município, em detrimento de valores absolutos.

Relativamente aos datasets de sucesso, foram obtidos dois conjuntos de dados diferentes. Por um lado, foram obtidas as médias dos exames (Físico-química, Português, Matemática e Total), das escolas, sendo consultada a informação dos rankings de escolas, publicada anualmente em diversos jornais. Optou-se por utilizar o último ano para o qual existia informação, tanto dos rankings como dos dados socioeconómicos. Após termos os dados com as médias por escola e o número de alunos respetivo, foi possível utilizar informação sobre a localização das escolas para permitir calcular as médias de exames por município.

Por outro lado, foram também obtidas as taxas de sucesso, calculadas através da análise da percentagem do número de alunos que transita, em cada ano curricular, no ensino geral, cursos científico-humanísticos e com planos próprios, obtida através da base de dados fornecida pela DGEEC e calculada para cada município.

Após integrar todos os dados foi também feita uma análise exploratória de dados que permitiu compreender a distribuição dos diferentes atributos, os seus valores mínimo e máximo, bem como identificar atributos não preenchidos em alguns municípios. Nos casos em que, para determinado atributo socioeconómico, mais de 50% dos municípios não tivessem dados preenchidos optou por se excluir esse atributo do dataset, ficando, após esta fase, 775 atributos disponíveis.

Nos casos em que, mesmo após filtrar os atributos, ainda permaneciam dados em falta, foi feito um processamento para calcular estes valores, que será descrito na seção seguinte.

5. K-Nearest Neighbours

Para que fosse possível obter os valores em falta para alguns dos atributos socioeconómicos, em alguns dos municípios, foi utilizada uma adaptação do algoritmo de K-Nearest Neighbours. Este algoritmo permite classificar um dado não classificado, através da medição da distância a outros dados classificados, e escolhendo a classificação dos vizinhos aos quais a distância é menor.

No caso dos atributos socioeconómicos, foi primeiro necessário proceder à normalização de todos os atributos, utilizando informação sobre o valor máximo e mínimo de cada atributo e normalizando para um valor entre 0 e 1.

Após a normalização, foi calculada, para cada categoria de atributos (ciência, educação, emprego, etc.), uma matriz com a distância entre todos os municípios, utilizando informação dos atributos preenchidos que estavam incluídos nessa categoria, bem como de alguns atributos base (como por exemplo, a população, densidade populacional, etc). Para calcular as distâncias utilizou-se o cálculo da distância euclidiana, em n dimensões, sendo n o número de atributos considerado.

De seguida, foi utilizada a matriz criada para gerar, para cada município uma lista ordenada com os municípios com menor distância.

Desta forma, para cada atributo não preenchido, foi possível utilizar a lista de vizinhos mais próximos na categoria do atributo e calcular a média do atributo em falta, utilizando o valor dos k vizinhos mais próximos, tendo-se optado por um valor de $k = 5$.

6. Criação das árvores

Após ter sido criado um dataset com todos os dados preenchido foi possível utilizar estes dados para a criação de árvores de decisão e regressão. Para tal foi utilizada a biblioteca scikit-learn e os métodos respetivos para criação das árvores.

Optou por ser testar a criação de árvores de decisão, que permitem classificar os dados, sendo neste caso utilizada uma classificação que diferenciava os municípios acima e abaixo da média dos exames, e também acima ou abaixo da taxa média de sucesso. Foram também criadas árvores de regressão que, em vez de classificar, permitem prever um resultado (média dos exames ou taxa de sucesso) consoante a escolha dos valores dos atributos.

Uma vez que para a criação de árvores é necessário escolher um conjunto de parâmetros que têm influência no resultado, foi utilizado um método de pesquisa em grelha para perceber qual a combinação de parâmetros que permitia obter árvores com menor erro associado. Este processo permitiu testar, por exemplo, qual a profundidade máxima da árvore, o menor número de amostras por divisão da árvore, o menor número de amostras nas folhas da árvore e o número máximo de folhas, entre outros.

7. Resultados

Após obter os parâmetros otimizados para cada tipo de árvore, e dados alvo (média de exame ou taxa de sucesso) foi possível obter as árvores de decisão e regressão. Por questões de espaço e conseqüente legibilidade, serão apresentados excertos das árvores geradas e não a sua totalidade.

Na figura 3 é apresentado um exemplo de uma árvore de decisão, na qual, em cada nó é apresentado o atributo socioeconómico e ponto de divisão que permitem obter o maior ganho de informação. Este processo é replicado até à obtenção dos nós folha, sem posteriores divisões, de acordo com os parâmetros escolhidos para a geração da árvore. Nos gráficos gerados é possível visualizar, em cada nó, qual a distribuição de quantos municípios estão presentes, por valor do atributo, em cada categoria, especificamente, a amarelo os que tem médias de exames menores que a média nacional e, a verde, os que tem médias maiores.

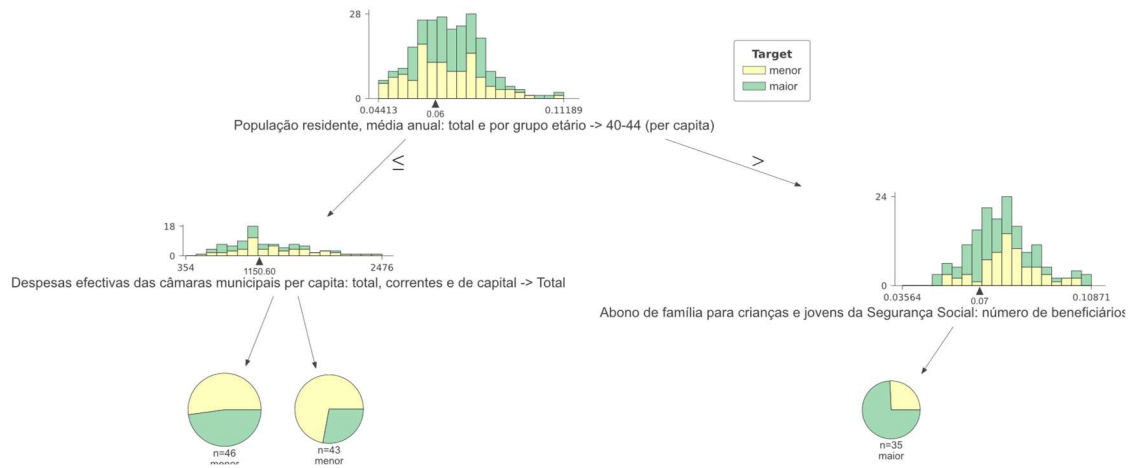


Figura 3 – Exemplo de árvore de decisão.

De igual forma, na figura 4 é apresentado um excerto de uma árvore de regressão obtida através de um processo semelhante aos das árvores de decisão, mas em que o objetivo é o cálculo de um valor provável para a média de exames, ao invés de uma classificação em maior ou menor que a média nacional.

No caso do gráfico das árvores de regressão é apresentada, em cada nó, a distribuição dos valores de médias de exame, no eixo das ordenadas e o valor do atributo utilizado no eixo das abcissas. É ainda apresentado o ponto de divisão, através do qual os pontos menores ou iguais são apresentados no ramo da esquerda e os maiores no ramo da direita.

Olhando para as árvores finais, é possível verificar que, em geral, os valores da entropia (no caso das árvores de decisão) e do erro quadrado (nas árvores de regressão) são relativamente altos, indicando a impossibilidade de encontrar fortes correlações entre os valores dos atributos socioeconómicos com as médias dos exames dos municípios.

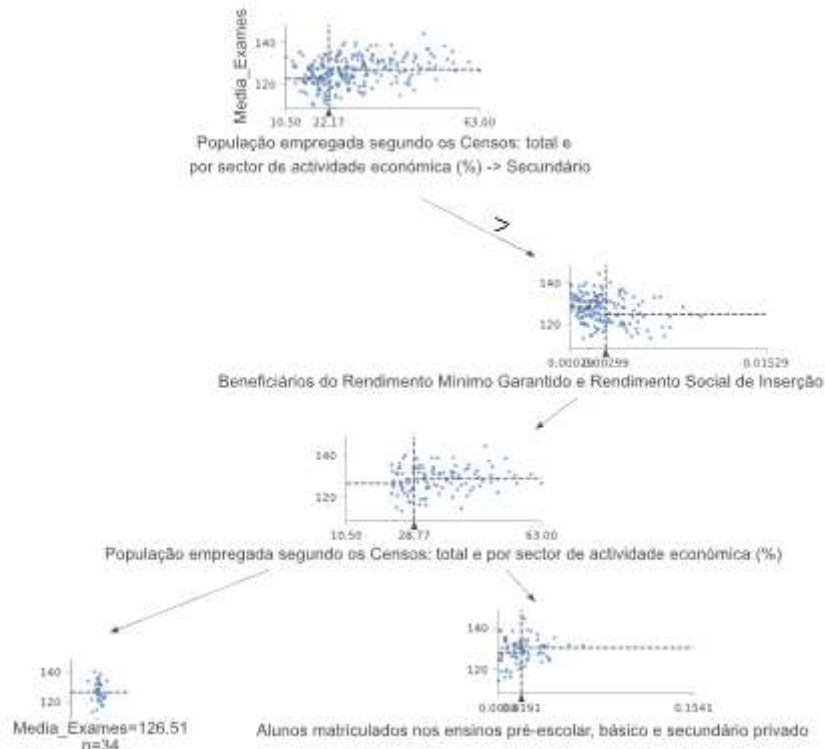


Figura 4 – Exemplo de árvore de regressão.

Apesar deste fato, alguns atributos chamam a atenção por conseguir obter menores taxas de erro e permitirem, localmente, alguma distinção entre os municípios com maiores e menores médias de exames, ou diferentes níveis de sucesso.

No caso do estudo das médias dos exames, ao olhar a árvore de decisão, é interessante notar que o nó selecionado para raiz da árvore está associado ao atributo da produtividade aparente das empresas do sector da atividade económica, com uma ligeira preponderância de municípios com resultados piores se a produtividade for menor e em sentido inverso se a produtividade for melhor (Figura 5).

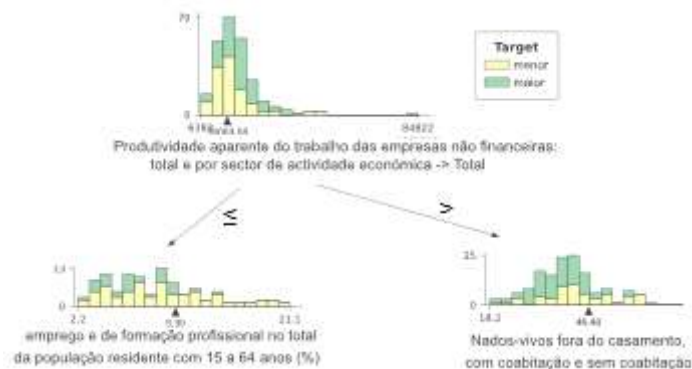


Figura 5 – Árvore de decisão - médias dos exames - Produtividade.

É possível ainda perceber que os atributos associados ao desemprego obtêm valores de entropia menores. Desta forma, é possível associar um maior número de desempregados, inscritos nos centros de emprego, entre os 15 e 64 anos, com municípios classificados com menores médias de exames (entropia = 0,381) (Figura 6). Do mesmo modo, o atributo associado à taxa de emprego é selecionado noutra ramo para indicar municípios com menor taxa de emprego como tendo piores resultados (Figura 7).

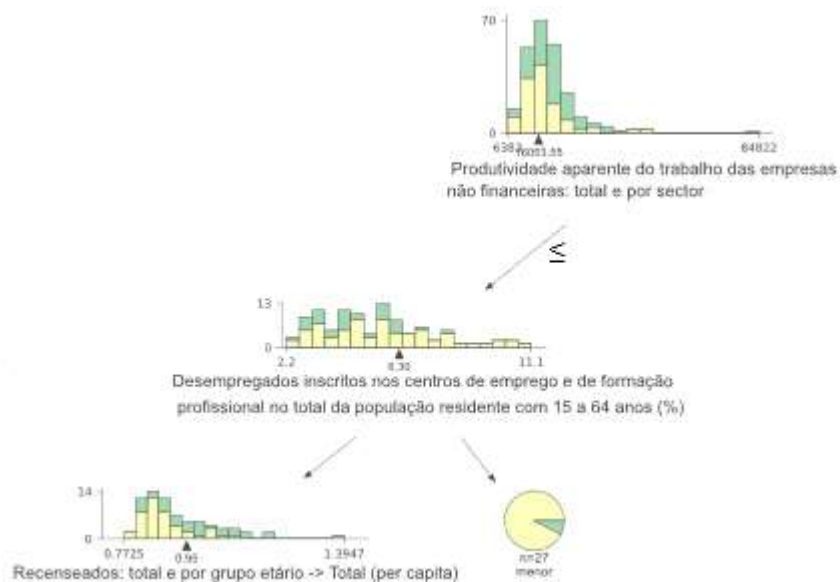


Figura 6 – Árvore de decisão - médias dos exames - Desempregados.




Figura 7 – Árvore de decisão - médias dos exames – Taxa de Emprego.

Analisando as árvores de regressão, para os mesmos dados, o nó selecionado para a raiz, escolhido por estar associado ao maior ganho de informação, reflete o índice de envelhecimento dos docentes em exercício no 2º ciclo do ensino básico, sendo interessante notar que são os municípios com maior índice de envelhecimento os que tem melhores resultados (média de 129,2 vs. 122,3 valores), tendo estes, no entanto, um elevado erro quadrado, pelo que não é possível indicar uma diferença estatisticamente significativa (Figura 8).

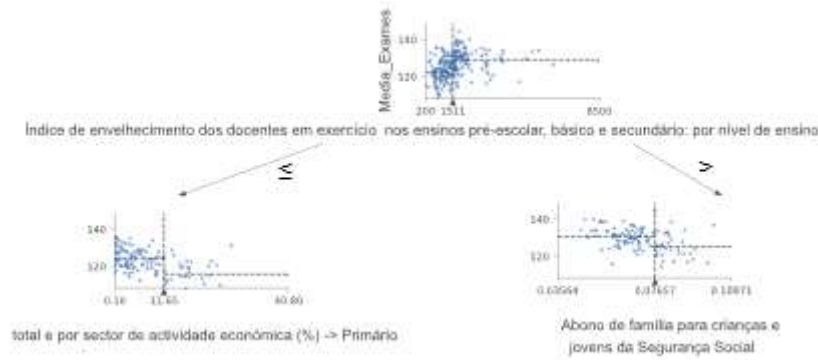


Figura 8 – Árvore de regressão - médias dos exames – Índice de Envelhecimento.

É também interessante notar a presença de um nó associado à população empregada no sector primário, em que municípios com mais gente a trabalhar neste sector tem médias menores (115,8 vs. 124,5 valores), existindo, no entanto, também um elevado erro quadrado (Figura 9). Por último, deve ser destacado o nó associado ao atributo do número médio de alunos por computador, no ensino secundário, em que um menor número está associado a médias mais baixas (121,0 vs. 125,1 valores), neste caso com um erro quadrado menor (Figura 10).

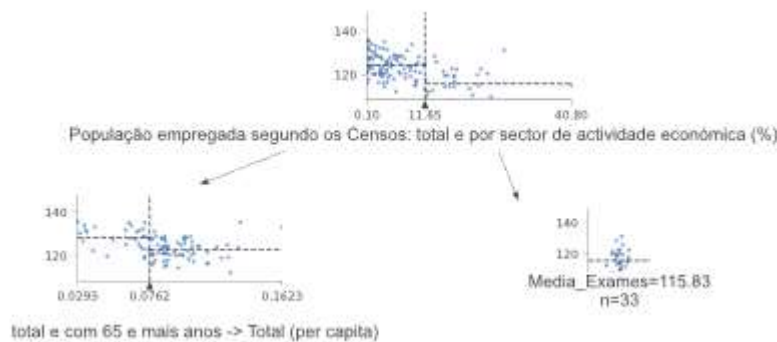


Figura 9 – Árvore de regressão - médias dos exames – População do sector primário.




Figura 10 – Árvore de regressão - médias dos exames – Alunos por computador.

Relativamente às árvores geradas através da análise das taxas de sucesso, extraídas da base de dados da DGEEC, as árvores de decisão mostram também entropias altas, sendo apenas de destacar os atributos selecionado para raiz, que caracteriza a percentagem de população estrangeira feminina na população residente, com menores percentagens associadas a um maior número de municípios com valores acima da média (Figura 11).




Figura 11 – Árvore de regressão – taxas de sucesso.

Por último, a análise das árvores de regressão geradas com as taxas de sucesso, indica, de forma interessante, um conjunto de nós que estão selecionados de dois tópicos diferentes: taxa de desemprego entre os 15 e os 24 anos, desempregados inscritos nos centros de emprego, sem nível de escolaridade, e população ativa com 65 ou mais anos. Apesar de as diferenças entre as taxas de sucesso não serem muito grandes, é relevante que metade dos nós tenham sido selecionados em tópicos relacionados com o emprego.

Do mesmo modo, os restantes nós estão todos relacionado às famílias, nomeadamente: população casada per capita, divórcios entre pessoas do sexo oposto em casamento civil e nados-vivos fora do casamento. Sendo que, novamente, apesar de diferenças pequenas, existem neste caso valores próximos da significância estatística.

8. Conclusões

Após ter terminado este trabalho, é possível perceber que o erro associado às árvores não permite tirar conclusões fortes acerca da existência, ou não, de uma correlação entre alguns atributos socioeconómicos e os resultados dos alunos em cada município. Adicionalmente, as diferentes árvores geradas nem sempre chegam aos mesmos atributos, excetuando os atributos relacionados com o emprego, que aparecem em diversas árvores.

Apesar de alguns dos resultados obtidos não revelarem resultados com correlações fortes, pensamos que os modelos e algoritmos utilizados fornecem uma boa base para projetos futuros que possam trabalhar com acesso a dados adicionais. Seria muito importante, por exemplo, ter informação acerca das avaliações dos alunos, de forma a permitir uma melhor definição e granularidade do conceito de sucesso escolar, e permitindo a potencial distinção de um maior número de grupos de alunos. Seria também relevante o acesso a maior número de dados socioeconómicos dos alunos e das suas famílias. A disponibilização desta informação tem relevância para a melhoria da criação de árvores de decisão que possam indicar de forma mais precisa quais os fatores socioeconómicos que têm mais impacto no sucesso escolar.

REFERÊNCIAS

Cavique, L., Pombinho, P., Tallón-Ballesteros, A. J., & Correia, L. (2020). Data Pre-processing and Data Generation in the Student Flow Case Study. In International Conference on Intelligent Data Engineering and Automated Learning (pp. 35-43). Springer, Cham.

Junior P.L., F.L. Silveira, F. Ostermann (2012), Survival analysis applied to student ow in undergraduate Physics courses: an example from a Brazilian university, Revista Brasileira de Ensino de Física, vol. 34 (1), 1403.

Lovell, C. C., (1971) Student Flow Models: A Review and Conceptualization. Western Interstate Commission for Higher Education, Boulder, Colo. National Center for Higher Education Management Systems.

Tavares, L.V. (1995), On the development of educational policies, European Journal of Operational Research, vol. 82(3), pp. 409–421.



Paulo Pombinho, Professor Auxiliar Convidado da Seção de Informática, Física e Tecnologia (SIFT), do Departamento de Ciências e Tecnologia (DCeT) da Universidade Aberta. Mestre (2009) e Doutor em Engenharia Informática (2015) pela Faculdade de Ciências da Universidade de Lisboa (FCUL). Investigador colaborador do Laboratório de Investigação LASIGE, da FCUL. Os interesses de investigação centram-se nas áreas da Ciência dos Dados, Context Awareness, Computação Móvel, Sistemas de Recomendação, Usabilidade e Visualização de Informação.



Luís Cavique, Professor Auxiliar da Secção de Informática, no Departamento de Ciências e Tecnologia (DCeT) da Universidade Aberta e Investigador no LaSIGE, FCUL. Licenciou-se em Engenharia de Informática pela Universidade Nova de Lisboa (FCT-UNL), é Mestre em Investigação Operacional e Engenharia de Sistemas pela Universidade Técnica de Lisboa (IST-UTL) e obteve o grau de Doutor em Engenharia de Sistemas da Universidade Técnica de Lisboa (IST-UTL) em 2002. Tem como área de investigação a Ciências dos Dados, recorrendo à interseção das Ciências da Computação com a Engenharia de Sistemas.



Luís Correia, Professor no Departamento de Informática da Faculdade de Ciências da Universidade de Lisboa. Licenciou-se em Engenharia Eletrotécnica pelo Instituto Superior Técnico da Universidade Técnica de Lisboa (1982), doutorou-se em Informática pela Universidade Nova de Lisboa (1995) e obteve agregação na Universidade de Lisboa (2009). Liderou o Laboratório de Modelação de Agentes, o LabMAg (2004-2014), o Departamento de Informática (2012-2015) e o grupo MAS da BioISI (2015-2020). Atualmente é investigador na LASIGE, ULisboa. Os seus interesses de investigação são a vida artificial, a auto-organização, os sistemas multi-agentes, os robôs autónomos e a mineração de dados.

(esta página par está propositadamente em branco)