

# EduVis: Visualização Interativa de Dados Educacionais

Sandra Gama Vilma Jordão Daniel Gonçalves  
INESC-ID e Instituto Superior Técnico, Universidade de Lisboa  
R. Alves Redol, 9, 1000-029 Lisboa, Portugal

sandra.gama@ist.utl.pt, vilma.jordao@ist.utl.pt, daniel.goncalves@inesc-id.pt

---

## Resumo

*Uma análise efetiva dos processos de ensino permite proporcionar à comunidade educativa um meio para analisar os resultados dos processos de ensino, apresentando potencial para ajudar a prevenir e corrigir situações problemáticas, levando a uma educação mais eficaz e bem sucedida. A aplicação de técnicas de data mining no âmbito da educação fornece ferramentas para analisar dados de ambientes educacionais, desde o comportamento dos alunos até às estratégias de ensino e coordenação de programas de estudos. No entanto, estes resultados incluem um amplo conjunto de comportamentos que consistem em padrões simbólicos, muitas vezes representados sob a forma textual, que normalmente é difícil de entender. Dado o potencial da visualização para representar grandes quantidades de dados, este método pode superar essa limitação, aliviando a carga cognitiva associada à interpretação de informação. Assim, utilizando os resultados de técnicas de data mining educacional que já tinha sido aplicado para analisar a interdependência entre as disciplinas de um curso universitário, foi desenvolvida uma visualização que permite a análise desses mesmos padrões. A visualização consiste em dois mecanismos distintos, mas coordenados, de representação de informação. O primeiro corresponde a uma visualização interativa multi-nível das disciplinas dos vários semestres do curso, em que as relações de precedência e simultaneidade são representadas através de conetores visuais. A segunda ferramenta, que consiste em matrizes multicamada, permite aplicar mecanismos de filtragem e explorar mais detalhadamente as relações entre as disciplinas. A complementaridade dos dois métodos de visualização permite tornar vários padrões imediatamente perceptíveis e permite a navegação e análise de informação. A elaboração de testes com utilizadores reiterou estas características, provando o potencial do sistema para possibilitar uma solução eficaz para a visualização de padrões educacionais.*

## Palavras-Chave

*Visualização de Informação, Análise Interativa de Dados Educacionais, Interação Pessoa-Máquina*

---

## 1. INTRODUÇÃO

O número de alunos, no ensino tradicional e nos cursos on-line, tem vindo a crescer nas últimas décadas. Quanto aos estudantes universitários, a taxa de escolarização mundial aumentou de 8.5%, em 1970, para 24.7%, em 2006 [Gao 10]. Quanto ao ensino on-line, a criação e a profusão de MOOC (Cursos Massivos Abertos Online), em que pessoas de todo o mundo podem participar, também contribuiu para um crescimento no número de estudantes a nível mundial. Como resultado, os CMS (Sistemas de Gestão de Cursos) e LMS (Sistemas de Gestão da Aprendizagem) tornaram-se populares e tiveram um grande impacto no reforço da educação à distância [Kay 13].

Compreender a eficácia de um programa de estudos ou de uma disciplina implica perceber como os alunos atingem o sucesso. Tendo em conta os cursos universitários, é importante analisar as taxas de sucesso das disciplinas e como se influenciam entre si. Este processo potencialmente ajudará a perceber e corrigir problemas e limitações, permitindo uma melhoria da adequação dos currículos, levando a melhores

resultados. Por outro lado, com o crescente número de estudantes no ensino tradicional e a profusão de cursos on-line, um extenso conjunto de dados emerge dos currículos dos alunos. Esta informação, se for explorada eficazmente, pode ser crucial para melhorar os processos de ensino.

A aplicação de técnicas de *data mining* neste contexto é um tema de pesquisa emergente, que tem vindo a fornecer meios para analisar dados educacionais, desde o comportamento dos alunos às estratégias de ensino e coordenação de cursos, assumindo a denominação de EDM (*Data Mining Educacional*). Tanto na educação on-line como na tradicional, a informação original não permite a análise direta de aspetos como, por exemplo, o comportamento dos alunos ou o sucesso das estratégias de ensino. No entanto, a EDM fornece padrões relevantes com base em informações disponíveis e faz com que seja possível fazer previsões com base nos dados educacionais. Contudo, o resultado normalmente consiste num extenso conjunto de comportamentos que são descritos sob a forma de padrões textuais que normalmente são difíceis de entender e inter-relacionar devido à sua complexidade visual. Adicionalmente, a com-

preensão deste tipo de informação muitas vezes implica um conhecimento razoável de algoritmos e estatística matemática, o que assume habilidades específicas que o utilizador pode não possuir. No entanto, essa limitação deve ser superada, uma vez que a interpretação desta informação é de extrema importância para que a EDM seja útil e eficaz.

Em termos gerais, não só é necessário perceber a informação a nível global, como um todo coerente, mas também compreender os padrões específicos e inter-relacionar informação. Fornecer os instrumentos para permitir uma interpretação fácil e correta dos dados educacionais é, portanto, de extrema importância. Para superar esse obstáculo e obter análise de dados eficaz, o utilizador deve estar envolvido no processo de exploração de uma forma que combine criatividade, flexibilidade e conhecimento geral [Keim 02]. A visualização tem potencial para superar este desafio, uma vez que é uma excelente forma para representar grandes quantidades de dados e alivia a carga cognitiva associada à interpretação de informação [Ware 12]. Como resultado, a criação de uma visualização que represente os resultados de *data mining* educacional terá boas possibilidades de fornecer à comunidade educativa informação relevante e perceptível neste contexto, permitindo compreender problemas que de outra forma permaneceriam despercebidos e procurar soluções adequadas.

Esta necessidade levou-nos a criar uma visualização que representa padrões educacionais, tornando evidente a sua navegação e análise eficaz. A informação representada consiste no resultado da aplicação de técnicas de EDM para analisar a interdependência entre os cursos num curso universitário [Antunes 08]. Estes padrões fornecem o número de alunos que obtêm sucesso a cada disciplina do curso, assim como informações relativas a relações de precedência e de simultaneidade entre disciplinas. Um exemplo de uma relação de precedência é: *50% dos estudantes que não conseguiram obter sucesso à cadeira A num determinado semestre, provavelmente não conseguirão completar a disciplina B no semestre seguinte*. Uma relação de simultaneidade pode ser: *25% dos alunos que foram aprovados na disciplina C num determinado semestre, também foram aprovados na cadeira D no mesmo semestre*. Assim, foi criada uma visualização que representa estes padrões e permite sua exploração através da coordenação de dois métodos interativos complementares: (i) uma visualização em camadas que tira partido de conectores visuais para representar relações de precedência e simultaneidade; (ii) uma visualização que fornece mecanismos de filtragem para exploração mais detalhada de padrões, utilizando mapas de cor para evidenciar relações entre disciplinas.

Na secção 2 são analisados e discutidos estudos relevantes no contexto da visualização de dados educacionais. Na secção 3 apresentamos os padrões obtidos a partir de EDM. Em seguida, é descrita a abordagem seguida relativamente à visualização e são detalhados os aspetos mais importantes da mesma. Na secção 5 são apresentados e analisados os resultados de avaliação com utilizadores da visualização criada. Por fim, são discutidas algumas conclusões relativas

ao presente estudo.

## 2. TRABALHO RELACIONADO

Com o crescimento do número de alunos no ensino tradicional e online, várias ferramentas foram criadas no âmbito da representação gráfica de informação educacional.

Tendo em conta a educação online, os CMS permitem a criação de salas de aula virtuais, onde alunos e professores podem partilhar informação, tornando possível a participação remota em discussões e a gestão de aulas. Este tipo de interação gera grandes quantidades de dados que precisam de ser geridos de uma forma que forneça aos professores informação relevante sobre o desempenho dos alunos. Para superar esse desafio, foi criado o CourseVis [Mazza 05], sendo usado como uma extensão ao CMS que permite a exploração interativa de dados e manipulação através de diferentes mecanismos de visualização. Um dos mecanismos é a representação tridimensional de participantes num fórum, em que os tópicos são representados como esferas com tamanho proporcional ao número de alunos envolvidos, permitindo *zoom* e visualização panorâmica. Outro mecanismo é a Matriz Cognitiva, que consiste de uma matriz na qual os nomes dos alunos são representados ao longo de um eixo e os conceitos da disciplina no outro eixo, sendo associada uma escala de cor ao desempenho, variando entre o verde (sucesso) e o vermelho (insucesso). Uma terceira ferramenta, que retrata o comportamento dos alunos através de gráficos e texto ordenados de forma matricial, tem como objetivo mostrar informação como o acesso aos conteúdos, a assiduidade e o progresso escolar. Um estudo com utilizadores mostrou que as representações gráficas do CourseVis permitem obter informação sobre os aspectos cognitivos dos estudantes de forma rápida e precisa. No entanto, os utilizadores tiveram alguns problemas na compreensão da informação devido à sobreposição de elementos visuais, resultando em dificuldade na leitura dos gráficos na representação do comportamento dos estudantes [NI11]. Estas limitações levaram à criação de GISMO (Sistema Gráfico Interativo de Monitorização de Estudantes), que representa visualmente dados de LMS, bastante complexos e difíceis de ler e entender. O GISMO está integrado no LMS Moodle mas pode também ser adaptado para outras plataformas de aprendizagem. Focado numa visualização de comportamentos bidimensional, o GISMO oferece uma visualização simples para parâmetros específicos. Permite a exploração interativa de acessos e detalhes de recursos, e fornece os meios para a exploração dos comportamentos dos alunos que tinham sido considerados relevantes no CourseVis [Mazza 05]. Tendo sido usado num curso online, o GISMO mostrou ser eficaz para a compreensão dos comportamentos individuais, bem como dos métodos de avaliação, permitindo redesenhar o curso de acordo com as necessidades dos alunos.

Dado que o ensino tradicional resulta de processos de avaliação, tais como notas de avaliação e outras competências, como assiduidade e participação, a informação resultante pode ser difícil de interpretar. Adicionalmente,

a descoberta de padrões e troca de informação são quase impraticáveis neste contexto. Um dos estudos que têm sido feitos no âmbito da visualização de informação para apoiar os processos educacionais é o AVOJ [Xiaohuan 13]. De modo a refletir as diferentes capacidades dos alunos, esta ferramenta permite a exploração e visualização de dados sobre o desempenho. Fornece meios para agrupar os alunos de acordo com suas notas e outros aspetos, como os hábitos de estudo. No entanto, faz uso de um esquema de cores com níveis máximos de brilho e saturação, competindo pela atenção visual do utilizador, o que torna mais difícil encontrar padrões [NI11]. O sistema oferece um mecanismo de visualização adicional para comparar tendências gerais, composto por um gráfico de barras que mostra estatísticas em tempo real, tornando possível compreender alguns aspectos específicos, como a forma como os alunos gerem as suas sessões de estudo. Os autores acreditam que, uma vez fornecendo um amplo conjunto de dados que não estavam disponíveis anteriormente, será possível obter mais informação sobre os processos educacionais e melhorar a eficácia do ensino. Outro estudo interessante é o de de Xiaoya et al. [Xiaoya 09], uma visualização para análise de resultados dos estudantes universitários num curso de Inglês. Seguem uma visualização de coordenadas paralelas, em que  $N$  eixos equidistantes são usados para representar as dimensões de um conjunto de dados multidimensional. No entanto, vários modelos adicionais têm sido utilizados: (i) classificação, que permite aos utilizadores dividir dados em conjuntos arbitrários de aulas, (ii) média, o que torna possível, por meio de interações com o gráfico principal, obter os valores médios de cada conjunto de dados ou subconjuntos de dados, (iii) *box plot*, para medir a dispersão dos dados, (iv) permuta de eixos, o que evidencia relações internas entre atributos; (v) correlação, para calcular a correlação entre dois conjuntos de dados ao longo de dois eixos paralelos, (vi) associação, no qual se pode prever a ocorrência de atributo A com base na ocorrência de atributo B, e (vii) *roll-up* e *drill*, permitindo a representação de dados de diferentes níveis hierárquicos. Estes modelos, além de permitirem a representação e manipulação interativa de dados, permitem uma visão geral imediata e mostram um número considerável de variáveis simultaneamente, permitindo uma análise mais eficiente e eficaz. Trimm et al. [Trimm 12] criaram uma visualização em que os alunos são agrupados de acordo com suas notas. Estes grupos podem ser visualizados utilizando composições que mostram as suas características e variações no tempo. A fim de utilizar a composição, a informação sobre o historial de cada aluno é constituída por uma trajetória bidimensional, representada em dois eixos. Esta representação, embora simples, não é muito eficiente para mostrar simultaneamente características e tendências de uma grande quantidade de dados dos estudantes. A visualização utiliza recursos espaciais para representar trajetórias dos alunos ao longo do tempo usando o algoritmo de nível definido. É utilizada uma técnica de mistura de cor para mostrar características como a média e o desvio padrão em relação aos resultados

dos alunos, representando a informação de uma forma natural, e é utilizada a técnica de *color weaving* para mostrar o valor de um determinado atributo em relação a uma trajetória selecionada aleatoriamente. No entanto, o uso de gradientes pode adicionar ruído à imagem e a variação de brilho e saturação pode também causar a ilusão de proximidade, levando a uma interpretação imprecisa dos dados. No entanto, testes com utilizadores mostraram que esta visualização fornece meios para encontrar novos padrões relevantes nos dados. A fim de entender o abandono escolar de um número significativo de estudantes relativamente a um curso de ciência da computação, foi desenvolvida uma ferramenta que permite a visualização de padrões de repetição de sucesso ou insucesso [Wortman 07]. Devido à grande quantidade de informação disponível, foi usada uma estrutura visual de nós e arestas. Os nós representam eventos, com largura proporcional ao número de estudantes de cada evento, e as arestas representam a trajetória dos estudantes relativamente aos eventos (exames ou trabalhos), sendo a largura representativa do número de alunos a ser descritos neste comportamento. As cores representam o desempenho dos alunos, permitindo diferenciar grupos de estudantes, identificando os que têm comportamento similar. A visualização é interativa, permitindo a seleção de categorias de estudantes, como *alunos que repetem pelo menos uma disciplina* ou *alunos que nunca reprovaram uma disciplina*. Como resultado, foi possível aos professores obter um conjunto de conclusões a respeito de falhas repetitivas ou implicações de uma determinada cadeira no sucesso noutras disciplinas. A estrutura visual tem, contudo, uma importante lacuna no que diz respeito à sobreposição das linhas mais grossas às mais finas, o que pode tornar difícil perceber alguma informação.

Todas as abordagens mencionadas focam a visualização de informação relativamente aos processos de ensino, tradicional ou on-line. Apresentam diferentes técnicas e metodologias para visualizar os dados neste contexto em particular. Dado o âmbito do presente estudo e as particularidades dos dados que pretendemos analisar, em que uma visualização que permita inter-relacionar disciplinas e mostrar as suas interdependências apresenta maior relevância, destacamos o trabalho de Wortman e Rheingans [Wortman 07] e, mais recentemente, o de de Trimm et al. [Trimm 12]. Uma visualização interativa que permita mecanismos interativos, como destaque, comparação e filtragem, é de extrema importância no âmbito deste estudo. No entanto, o último trabalho supracitado, de Trimm et al. [Trimm 12], oferece interação limitada sobre as particularidades de nosso contexto. Além disso, o estudo de Wortman e Rheingans [Wortman 07], apesar de proporcionar mecanismos de interação, não permite comparação entre disciplinas ou destaque de padrões específicos. Além disso, o esquema de cores usado não alivia a confusão visual que está presente quando muitas arestas diferentes são representadas. Desenvolvemos, assim, uma técnica de visualização que representa as inter-relações entre as disciplinas de um programa de estudos na tentativa de colmatar as lacunas das soluções existentes neste contexto.

### 3. PADRÕES EDUCACIONAIS

Um dos desafios na utilização de dados de ensino de modo a melhorar o sucesso é a aquisição de conhecimento do contexto, no que diz respeito a estratégias de ensino atuais e aos comportamentos dos alunos. Neste estudo foi utilizado o resultado de *data mining* sequencial que tinha sido anteriormente aplicado a dados recolhidos durante nove anos num programa de estudos em ciência da computação [Antunes 08]. O objetivo do *data mining* sequencial é, dado um conjunto de sequências e um limiar de suporte mínimo, descobrir o conjunto de sequências que estão contidas em pelo menos  $\sigma$  sequências do conjunto de dados, isto é, o conjunto de sequências frequentes [Agrawal 95]. Esta técnica permite a descoberta de padrões sequenciais frequentes, sendo estes consistentes com o conhecimento de fundo existente. Tal conhecimento pode ser representado por uma linguagem livre de contexto, que desempenha o papel de uma restrição no processo de *data mining* sequencial. Este método não só reúne padrões esperados com base no conhecimento de fundo mas, com o uso de relaxamentos, permite também a descoberta de padrões que correspondem a desvios ao comportamento esperado, tornando evidentes algumas tendências potencialmente relevantes que antes eram desconhecidas [Antunes 08]. Assim, o conhecimento do currículo escolar foi representado como um autómato finito, estabelecendo a ordem das disciplinas que os alunos deviam completar para concluir o curso. O *data mining* sequencial com três diferentes valores de limiar de suporte (50 %, 25 % e 20 %) foi realizado, resultando em três diferentes conjuntos de padrões. Evidentemente, quanto menor é o valor do limiar de suporte, maior é o número de padrões resultante da aplicação do *data mining* sequencial. Como um resultado da aplicação do método acima referido, foi gerado um conjunto de padrões textuais. Os padrões observam a seguinte estrutura:

$$\text{Padrao}_i = (\text{semestre}_1, \dots, \text{semestre}_N, \text{total}_{\text{alunos}}),$$
$$\text{semestre}_j = \text{disciplina}_1 \vee (\text{disciplina}_1, \dots, \text{disciplina}_M)$$

Alguns exemplos são os seguintes:

- $(fex, 2000)$ : 2000 alunos concluíram *fex* no primeiro semestre;
- $(fex, tc, 1400)$ : 1400 alunos concluíram *fex* e *tc* no segundo semestre;
- $((fex, AM1), tc, 1000)$ : 1000 alunos concluíram *fex* e *am1* no primeiro semestre e *tc* no segundo semestre;
- $((fex, AM1), (fisica1, tc), AM2, 800)$ : 800 alunos completaram *fex* e *am1* no primeiro semestre, seguido por *fisica1* e *tc* no segundo semestre e *am2* no terceiro semestre.

Embora a informação textual torne difícil entender padrões específicos e forneça pouca informação geral, esta estrutura de padrões disponibiliza informação sobre as interações entre os diferentes semestres do curso que uma visualização eficaz será capaz de tornar evidente.

### 4. VISUALIZAÇÃO DE DADOS EDUCACIONAIS

Tendo em conta o contexto do estudo e os padrões a representar, foi criada uma visualização que mostra relações de dependência entre cadeiras, permitindo saber qual ou quais as disciplinas mais importantes por influenciarem o sucesso dos alunos ao longo do percurso escolar. Para tal, foi criado o EduVis, uma visualização coordenada, representada na Figura 1, que tira partido da conjugação de duas ferramentas principais: (i) uma representação multi-camada das disciplinas do programa curricular, inter-relacionadas através de conetores visuais; e (ii) uma representação multi-matricial em que são apresentadas as disciplinas, sendo os respetivos padrões representados através de mapas de cor. As duas ferramentas possuem características distintas e têm funcionalidades complementares. As seções seguintes descrevem em detalhe cada uma das ferramentas principais da visualização e descrevem os mecanismos de interação.

#### 4.1. Visualização multi-camada

Nesta visualização, cada nível corresponde a um semestre de um programa curricular, representando as disciplinas desse semestre que têm algum tipo de relação com outras. Assim, as cadeiras são geralmente representadas como círculos verdes com tamanho proporcional ao número total de estudantes que as completaram. Quando existem dados sobre o insucesso, o círculo da cadeira é sub-dividido em dois semicírculos, mostrando informação sobre a aprovação e a reprovação através do código convencional ocidental de cor [Ware 12]. O verde, à esquerda, representa o número de alunos aprovados e o vermelho, à direita, mostra o número de estudantes que reprovaram, como representado na Figura 2. Este mecanismo, embora simples, torna possível entender imediatamente as disciplinas com elevada ou baixa taxa de sucesso, assim como comparar visualmente o sucesso e o insucesso de uma disciplina, sem a necessidade de exploração adicional.

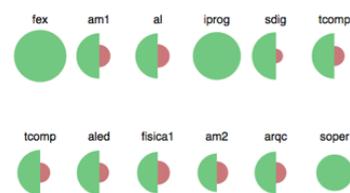


Figura 2. Visualização multi-camada

#### 4.2. Visualização multi-matricial

Nesta visualização as matrizes representam as disciplinas do curso, sendo cada disciplina correspondente a um quadrado, que se divide em dois triângulos: o superior representa sucesso e o inferior representa insucesso. Antes de qualquer interação, ou seja, no estado inicial da visualização, como representado na Figura 3, as cadeiras sobre as quais existe informação são representadas por cores entre o amarelo e o azul escuro, enquanto as disciplinas sem padrões são representadas a cinzento. O brilho repre-



Figura 1. EduVis: Visualização principal

senta o número de padrões em que as cadeiras estão envolvidas: quanto menor o brilho (mais "escura" a cor), mais relações com outras cadeiras essa disciplina tem. Se existirem poucas ou nenhuma dependências, então fica associada a um tom com brilho elevado (um tom mais "claro").



Figura 3. Visualização multi-matricial

### 4.3. Interação

A interação inicia-se quando uma disciplina é seleccionada, em qualquer uma das visualizações. Na representação multi-camada, esta ação corresponde ao movimento do cursor sobre o semi-círculo correspondente à aprovação ou reprovação, enquanto que na representação multi-matricial ocorre com o movimento do cursor sobre um triângulo, correspondente também à aprovação ou reprovação de uma cadeira. Sendo uma disciplina seleccionada, ambas as visualizações refletem essa seleção. Na visualização multi-camada é destacado o círculo atual, sendo atribuída mais saturação ao mesmo, e é representada informação sobre as relações desta cadeira com as restantes através de conetores visuais. Estes consistem em curvas de Bézier cúbicas

com espessura proporcional ao número de alunos que verificam o padrão, informação que é reforçada pela cor, utilizando convenções ocidentais de mapas de calor [Ware 12]. Assim, padrões que surjam de cadeiras com aprovação (semi-círculos verdes) são representados com cores entre o azul (menor quantidade de alunos) e o verde (maior quantidade), como ilustrado na Figura 4. De forma análoga, padrões que surjam de reprovações (semi-círculos vermelhos) são representados com cores entre o amarelo (menor quantidade de alunos) e o vermelho (maior quantidade). Não são, no entanto, usadas cores totalmente saturadas, a fim de evitar que os artefactos visuais compitam pela atenção do utilizador [Ware 12]. Quando o cursor sai do círculo, a informação relativa às relações com outras disciplinas deixa de ser representada.

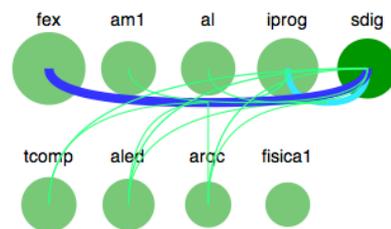
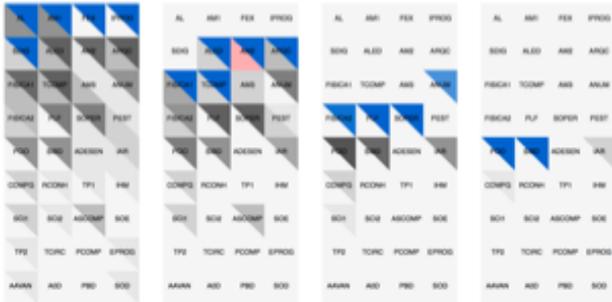


Figura 4. Visualização multi-camada (disciplina *sdig*)

Na visualização multi-matricial, as alterações refletem-se essencialmente a nível da cor. Assim, para demonstrar as dependências, são usadas duas cores, azul e vermelho, que correspondem a um mapa de calor relativamente à aprovação e reprovação: o triângulo superior, represen-

tado em azul, está associado às aprovações, e o inferior, vermelho, representa as reprovações. Ao ser colocado o cursor sobre um triângulo, são representadas as cadeiras com que esta está relacionada, a nível de aprovações e reprovações, como ilustrado na Figura 5, correspondente à seleção da disciplina *am1* no primeiro semestre. De forma semelhante à visualização multi-camada, quando o cursor sai do triângulo, a informação relativa às relações com outras disciplinas deixa de ser representada.



**Figura 5. Visualização multi-matricial (disciplina *am1*)**

Adicionalmente, sempre que uma disciplina é selecionada, é apresentada, no painel retangular entre as duas visualizações, informação detalhada sobre os padrões relacionados com essa disciplina. Quando um padrão é selecionado nesta lista, a informação correspondente reflete-se na visualização principal.

O EduVis possibilita a comparação simultânea de disciplinas. Na visualização multi-camada, ao clicar sobre um semi-círculo, este fica selecionado, não desaparecendo os seus padrões com o deslocar do cursor. De forma similar, na visualização multi-matricial, clicar nos triângulos fixa os padrões correspondentes e a disciplina selecionada fica em destaque com um contorno laranja. Desta forma, ao ser selecionada outra disciplina (através do deslocamento do cursor sobre a mesma), é possível comparar duas cadeiras simultaneamente em ambas as visualizações.

A visualização matricial disponibiliza ainda mecanismos de filtragem para exploração de padrões. Ao passar o cursor sobre os padrões de uma cadeira previamente selecionada, são visíveis as relações comuns entre a cadeira inicial e a cadeira onde se encontra o cursor atualmente. Ao clicar num triângulo dessa cadeira, apenas ficam visíveis os padrões comuns às duas cadeiras selecionadas, como representado na Figura 1. Faz-se assim uma restrição ao conjunto de relações iniciais da primeira disciplina selecionada. Assim, é possível fazer restrições indefinidamente, até ao ponto limite em que todas as cadeiras representadas fazem parte do mesmo conjunto de relações.

O EduVis tem, assim, três aspectos principais. O primeiro é leitura imediata de informação: pode-se perceber o número de semestres, bem como o número de disciplinas para cada nível e reconhecer de imediato as cadeiras concluídas por um maior número de alunos e as mais

problemáticas. Outro aspecto importante é a exploração de dados: quando uma disciplina está selecionada, é representada informação, nomeadamente relativa às relações com outras cadeiras, que é o foco dos padrões que pretendemos representar. Finalmente, o sistema fornece mecanismos de comparação e filtragem interativas, permitindo a comparação entre cadeiras e permitindo criar restrições à informação representada, fornecendo ferramentas para uma exploração simples e eficiente.

## 5. AVALIAÇÃO

Foi realizado um estudo com utilizadores para avaliar a solução criada para a visualização de padrões educacionais. Como resultado, tendo em conta o contexto do estudo supracitado, pretendemos inferir: (i) a eficácia e eficiência da nossa solução, tendo para isso registado o tempo e número de erros associado ao desempenho de um conjunto de tarefas; (ii) a usabilidade, em geral, e a capacidade de aprendizagem, em particular, que o contacto com a visualização criada proporciona; (iii) o grau de satisfação dos inquiridos em relação ao desempenho das tarefas.

### 5.1. Tarefas Representativas do Sistema

Relativamente às tarefas selecionadas para avaliar a visualização desenvolvida, foi criado um conjunto de perguntas representativas dos principais componentes e funcionalidades: (1) *Quantos semestres são representados?* (2) *A nível geral, quais são as duas cadeiras com mais alunos?* (3) *Qual o conjunto de cadeiras envolvidas em mais padrões no segundo semestre?* (4) *Quais as cadeiras relacionadas com iar no quarto semestre?* (5) *Considerando os alunos que fizeram *am1* e *fisica1*, quais são as outras cadeiras em que também obtiveram sucesso no segundo semestre?* (6) *Quais são as cadeiras comuns a quem fez *sdig* no primeiro semestre e obteve reprovação a *aled* no segundo semestre?* (7) *Considerando a cadeira *fisica2* no terceiro semestre, embora seja a que tem mais padrões associados, é esta a cadeira com mais alunos nesse semestre?*

As perguntas 1, 2 e 3 correspondem a aspetos gerais imediatamente perceptíveis na visualização: o número de semestres é visível em ambas as visualizações, representado pelas camadas de círculos na visualização superior e matrizes na inferior. Na primeira visualização consegue-se imediatamente verificar, através do tamanho dos círculos, as cadeiras com mais alunos. Finalmente, na representação inferior consegue ver-se imediatamente quais são as cadeiras envolvidas em mais padrões, através do destaque que é feito com recurso à cor. A questão 4 requer exploração de qualquer um dos mecanismos de visualização, selecionando a cadeira de interesse em qualquer uma das ferramentas. A questão 5 requer a aplicação de filtros na visualização inferior para se conseguir responder, enquanto a questão 6 obriga a que se utilizem filtros e se perceba a mistura de cor. Finalmente, a questão 7 requer que o utilizador utilize uma conjugação de ambas as visualizações, a inferior para perceber que de facto a cadeira é a que tem mais padrões e a superior para perceber o número de alunos da cadeira mencionada, face às restantes.

## 5.2. Protocolo de teste

Antes de iniciar os testes, os participantes foram abordados individualmente, tendo-lhes sido explicado o contexto do presente estudo e pedida a sua colaboração. Depois de uma descrição verbal da visualização e dos seus componentes fundamentais, as principais funcionalidades foram exemplificadas. De seguida, foi entregue aos participantes um questionário com algumas perguntas de perfil e uma lista de outras perguntas, correspondentes a um conjunto de tarefas a realizar. Estas perguntas deviam ser respondidas durante a interação com a visualização, através de um computador portátil (comum a todos os utilizadores). Durante esta fase de teste, foi medido o tempo e o número de erros para cada tarefa. No final, os participantes foram encorajados a fazer comentários verbais ao sistema. Por último, foi-lhes pedido que preenchessem um questionário *online* de satisfação, consistindo em duas partes: a primeira parte corresponde ao SUS (*System Usability Scale*) [Brooke 96] e a segunda diz respeito a um pequeno conjunto de perguntas que têm como objetivo avaliar, também usando uma escala de Likert de 5 pontos, o grau de dificuldade sentido pelos participantes ao realizar cada tarefa, na compreensão dos seguintes aspetos: (i) o número de semestres representados, (ii) o sucesso e o insucesso, (iii) as cadeiras envolvidas em mais padrões, (iv) as relações de precedência entre as cadeiras, e (v) os padrões que envolvem diferentes cadeiras simultaneamente.

## 5.3. Resultados

O estudo foi realizado com 20 participantes, dos quais 15 (75%) são do género masculino e 5 (25%) do género feminino. Do total de participantes, 3 (15%) têm entre 18 e 24 anos de idade, 10 (50%) entre 25 e 34 anos e 3 (15%) têm entre 35 e 44 anos, além de que 2 (10%) têm entre 45 e 54, 1 (5%) entre 55 e 64 anos e 1 (5%) está situado na faixa etária superior aos 65 anos de idade. Quanto à escolaridade, 16 (80%) têm um curso superior, enquanto 2 (10%) completaram o ensino secundário e 2 (10%) concluíram os estudos do ensino básico.

**Tabela 1. Tempo e número de erros médio**

Tarefa	Tempo (segundos)	Número de erros
1	3.20	0.35
2	17.60	0.10
3	28.30	0.55
4	23.95	0.30
5	27.70	0.30
6	49.45	0.75
7	45.70	0.30

Relativamente aos tempos médios e número de erros médio relativos ao desempenho de cada uma das tarefas, estes são sumarizados na tabela 1. Embora as tarefas 1, 2 e 3 sejam imediatas e portanto não necessitem de exploração adicional, os valores medidos não permitem criar uma generalização acerca do tempo e número de erros para desempenho destas tarefas face às tarefas de exploração (4

a 7), com possível exceção das tarefas 6 e 7. Para aprofundamento dos resultados, conduzimos uma análise estatística. Foi aplicado um teste estatístico Shapiro-Wilk, que mostrou evidência contra uma distribuição normal na maior parte dos dados ( $p < 0.05$ ), pelo que aplicámos um teste não paramétrico, o teste *Wilcoxon signed-rank* para descobrir diferenças significativas entre amostras. De facto, a nível de tempo, a tarefa 1 é significativamente mais rápida que as restantes ( $z_{1-2} = -3.72$ ,  $z_{1-3} = -3.92$ ,  $z_{1-4} = -3.92$ ,  $z_{1-5} = -3.92$ ,  $z_{1-6} = -3.92$ ,  $z_{1-7} = -3.92$ ,  $p < 0.05$ ), enquanto a tarefa 2 é significativamente mais rápida que as tarefas 3, 5, 6 e 7 ( $z_{2-3} = -2.39$ ,  $z_{2-5} = -2.54$ ,  $z_{2-6} = -3.32$ ,  $z_{2-7} = -3.25$ ,  $p < 0.05$ ). Por outro lado, as tarefas 3, 4 e 5 são significativamente mais rápidas que as tarefas 6 e 7 ( $z_{3-6} = -2.31$ ,  $z_{3-7} = -2.17$ ,  $z_{4-6} = -3.45$ ,  $z_{4-7} = -2.76$ ,  $z_{5-6} = -3.36$ ,  $z_{5-7} = -2.63$ ,  $p < 0.05$ ). No entanto, no que diz respeito ao número de erros, existem diferenças significativas apenas entre a tarefa 6 e as que têm menos erros, a tarefa 2 ( $W = 6$ ,  $cv = 17$ ,  $p < 0.05$ ) e a tarefa 4 ( $W = 0$ ,  $cv = 3$ ,  $p < 0.05$ ), e entre as tarefas 2 e 3 ( $W = 5$ ,  $cv = 8$ ,  $p < 0.05$ ). Numa tentativa de encontrar uma correlação entre o tempo e o número de erros, calculámos os coeficientes de Pearson, encontrando uma correlação, embora relativamente fraca, na tarefa 2 ( $r = 0.45$ ,  $p < 0.05$ ) e na tarefa 7 (0.49,  $p < 0.05$ ), o que não nos permite generalizar uma correlação entre um maior tempo para desempenho da tarefa e um maior número de erros. É possível concluir, assim, que a complexidade temporal de uma tarefa no EduVis não leva a um maior número de erros no desempenho da mesma.

Tendo em conta o questionário de satisfação, a pontuação relativa ao SUS segundo os correspondentes parâmetros de cálculo ([Sauro 11]), foi de 79.47 pontos, mostrando resultados bastante elevados no que diz respeito à usabilidade e capacidade de aprendizagem do sistema. Usando o mesmo método para calcular as respostas de satisfação contextuais, obtivemos um resultado 92.11 pontos, mostrando que nossos objetivos foram alcançados no que diz respeito à satisfação no desempenho das tarefas.

## 5.4. Discussão

Os resultados da avaliação mostraram que os utilizadores foram capazes de obter as informações necessárias para concluir as tarefas em tempo razoável e com número reduzido de erros. Para tarefas mais complexas, a necessidade de maior interação com o sistema reflete um natural aumento do tempo de desempenho da tarefa que, no entanto, não se traduz num aumento do número de erros, o que mostra que a visualização permite obter a informação necessária ao desempenho das tarefas de uma forma eficaz. Estes resultados foram corroborados pelos questionários de satisfação, que provaram a usabilidade do sistema e mostraram elevada satisfação por parte dos utilizadores. A conjugação destes aspetos mostra, assim, a eficácia do EduVis para a visualização de padrões educacionais.

## 6. CONCLUSÕES

Uma grande quantidade de dados emerge das atividades educacionais com o crescente número de estudantes no ensino tradicional e on-line. Analisada eficazmente, esta informação pode ajudar a refinar os processos de educação. Neste contexto, as técnicas de *data mining* têm mostrado ser relevantes para encontrar padrões nos dados, mas o resultado da aplicação dos mesmos leva muitas vezes a conjuntos de dados difíceis de ler, interpretar e analisar. Uma vez ultrapassada essa limitação será possível representar esta informação como um todo consistente e ter noção de aspectos particulares nos dados. Face a este desafio, criámos uma visualização que coordena dois diferentes mecanismos de interação complementares para visualizar relações entre unidades curriculares de um curso universitário. O EduVis fornece mecanismos de exploração, comparação simultânea e filtragem, permitindo gerir a informação. Tira partido da cor para destacar elementos visuais para enfatizar a informação relevante e aliviar a confusão visual associada à representação de um grande número de artefactos com propriedades semelhantes.

Os testes com utilizadores mostraram que a visualização torna imediatamente evidente um conjunto relevante de informação geral e permite uma fácil recolha de dados através de mecanismos de exploração e e comparação interativa. Os participantes perceberam imediatamente aspectos como o número de semestres representados, tal como as disciplinas com mais ou menos sucesso. Utilizaram os mecanismos disponíveis para comparar, filtrar e recolher informação e mostraram satisfação no desempenho das tarefas. Concluimos que o EduVis fornece os meios para representar os resultados de informação educacional de uma forma que proporciona à comunidade educativa perceber um conjunto de padrões que não seriam evidentes de outra forma. Fornecendo os meios para diagnosticar determinados problemas, o sistema será útil para que os coordenadores de programas de estudo, tal como os professores, tenham os meios para encontrar soluções para as limitações existentes, promovendo o sucesso na educação.

## 7. AGRADECIMENTOS

Este trabalho foi apoiado por fundos nacionais através da FCT (Fundação para a Ciência e a Tecnologia), no âmbito do projeto Educare - PTDC/EIA-EIA/110058/2009 e pelo fundo plurianual do INESC-ID - PEst-OE/EEI/LA0021/2013..

## Referências

- [Agrawal 95] R. Agrawal e R. Srikant. Mining sequential patterns. Em *Proceedings of the IEEE International Conference on Data Engineering*, páginas 3–14, 1995.
- [Antunes 08] C. Antunes. Acquiring background knowledge for intelligent tutoring systems. Em *Proceedings of the International Conference on Educational Data Mining*, páginas 18–27, 2008.

- [Brooke 96] J. Brooke. Sus: A quick and dirty usability scale, 1996.
- [Gao 10] Y. Gao. A study on mass higher education in the world-based on comparative perspectives. Em *International Conference on Education and Management Technology (ICEMT)*, páginas 528–530, 2010.
- [Kay 13] J. Kay, P. Reimann, E. Diebold, e B. Kummerfeld. Moocs: So many learners, so much potential ... *IEEE Intelligent Systems*, 28(3):70–77, 2013.
- [Keim 02] D. Keim. Information visualization and visual data mining. *IEEE Transactions on Visualization and Computer Graphics*, 8(1):1–8, 2002.
- [Mazza 05] R. Mazza e V. Dimitrova. Generation of graphical representations of student tracking data in course management systems. Em *Ninth International Conference on Information Visualisation, 2005. Proceedings*, páginas 253–258, 2005.
- [NI11] J. Steele N. Iliinsky. *Designing Data Visualizations*. O'Reilly, 2011.
- [Sauro 11] J. Sauro. *A Practical Guide to the System Usability Scale: Background, Benchmarks and Best Practices*. CreateSpace, 2011.
- [Trimm 12] D. Trimm, P. Rheingans, e M. desJardins. Visualizing student histories using clustering and composition. *IEEE Transactions on Visualization and Computer Graphics*, 18(12):2809–2818, 2012.
- [Ware 12] C. Ware. *Information Visualization: Perception for Design*. Elsevier, 2012.
- [Wortman 07] D. Wortman e P. Rheingans. Visualizing trends in student performance across computer science courses. Em *Proceedings of the 38th SIGCSE Technical Symposium on Computer Science Education*, páginas 430–434, 2007.
- [Xiaohuan 13] W. Xiaohuan, Y. Guodong, W. Huan, e H. Wei. Visual exploration for time series data using multivariate analysis method. Em *8th International Conference on Computer Science Education (ICCSE)*, páginas 1189–1193, 2013.
- [Xiaoya 09] G. Xiaoya, L. Kan, e L. Ping. Visual analysis of college students' scores in english test. Em *4th International Conference on Computer Science Education (ICCSE)*, páginas 1816–1819, 2009.