

Revisitando probabilidades de incumprimento de empresas

António Antunes
Banco de Portugal e NOVA SBE

Homero Gonçalves
Banco de Portugal

Pedro Prego
Banco de Portugal

Abril de 2016

Resumo

Este artigo apresenta um sistema de avaliação da qualidade creditícia das empresas não financeiras em Portugal. Na sua conceção, o objetivo principal passa por determinar os fatores que explicam a probabilidade de uma empresa ter um episódio de incumprimento de crédito significativo junto do sistema bancário no ano seguinte. Usando informação da central de responsabilidades de crédito para o período 2002–2015 e da central de balanços para o período 2005–2014, desenvolvemos um método para selecionar variáveis explicativas e estimar modelos de variável binária para dez estratos de empresas, definidos em termos de dimensão e setor de atividade económica. Esta metodologia é utilizada para classificar as empresas em termos de probabilidade de incumprimento a um ano, utilizando-se os valores de referência dos sistemas de notação de risco existentes, em particular no âmbito do Eurosistema. O documento apresenta uma breve caracterização do setor não financeiro português em termos de probabilidades de incumprimento e da transição entre as classes de notação de crédito. (JEL: C25, G24, G32)

Introdução

Este artigo apresenta um sistema de avaliação da qualidade creditícia das empresas não financeiras em Portugal. O objetivo principal é determinar os fatores que explicam a probabilidade de uma empresa ter um episódio de incumprimento de crédito significativo junto do sistema bancário no ano seguinte. O resultado deste sistema é uma probabilidade de incumprimento no crédito bancário no horizonte de um ano. Este valor é então mapeado para uma escala onde as empresas são agrupadas em classes homogêneas de risco. O facto da análise sobre a qualidade de crédito

Agradecimentos: Gostaríamos de agradecer a Lucena Vieira pela competência na disponibilização dos dados, a Manuel Lingo e Florian Resch (Banco Nacional da Áustria) por partilharem conosco a sua experiência na conceção de sistemas de notação de crédito, e aos nossos colegas do Departamento de Estatística e do Departamento de Estudos Económicos que nos ajudaram neste projeto.

E-mail: aantunes@bportugal.pt; hgoncalves@bportugal.pt; pmprego@bportugal.pt

<i>Credit Quality Step</i>	Limite superior de probabilidade de incumprimento
1 & 2	0,1
3	0,4
4	1,0
5	1,5
6	3,0
7	5,0
8	100

QUADRO 1. *Credit Quality Steps* no Eurosistema. Todos os valores em percentagem.

Fonte: BCE.

se centrar apenas em empréstimos bancários não restringe a sua aplicação por duas razões. Em primeiro lugar, a esmagadora maioria da dívida das empresas em Portugal é constituída por empréstimos bancários, sendo muito reduzido o número de empresas a emitir dívida titulada, normalmente grandes empresas. Em segundo lugar, o incumprimento na dívida titulada é altamente correlacionado com o incumprimento nos empréstimos bancários.

Cada classe de risco será identificada por uma notação de crédito a utilizar no resto deste artigo. Uma notação de crédito é então um indicador sintético que reflete várias características (por exemplo, solvência, liquidez, rendibilidade) e mede a capacidade da empresa em cumprir os seus compromissos financeiros.

Neste documento será usada a taxonomia do Eurosistema, onde uma notação de crédito é designada por *Credit Quality Step*. O Quadro 1 apresenta as diferentes classes e os limites superiores da probabilidade de incumprimento associados. Ver ECB (2015) para mais detalhes.

Este artigo recorre parcialmente ao trabalho anteriormente desenvolvido por Martinho e Antunes (2012), mas há uma vasta literatura académica sobre o tema (ver, por exemplo, Coppens *et al.* 2007; Lingo e Winkler 2008; Figlewski *et al.* 2012), bem como uma variedade de estudos produzidos por instituições públicas e privadas, incluindo o Banco Central Europeu (BCE), a Autoridade Bancária Europeia (EBA), a Fitch Ratings, a Moody's e a Standard & Poors.

As notações de crédito são usadas com diversas finalidades. A mais óbvia prende-se com o processo de concessão de crédito dos bancos. De facto, as notações de crédito são um instrumento muito importante para possibilitar a seleção de clientes de acordo com o nível de risco pré-definido por cada instituição financeira e para determinar também as próprias condições dos empréstimos. Uma notação de crédito mais positiva implica geralmente melhores condições de financiamento, incluindo menor custo e acesso a instrumentos mais diversificados como, por exemplo, o mercado de valores mobiliários.

Períodos de materialização mais acentuada do risco de crédito, como aquele observado recentemente em Portugal, colocam ainda mais ênfase

sobre a relevância do processo de avaliação de crédito. Os dados para 2015 mostram que a dívida total das sociedades não financeiras em Portugal representava 115% do PIB, um dos valores mais elevados na área do euro. Uma parte considerável dessa dívida está no balanço dos bancos, onde as sociedades não financeiras são responsáveis por cerca de 28% do crédito total (empréstimos bancários e títulos de dívida). A qualidade destes créditos tem vindo a deteriorar-se substancialmente nos últimos anos, colocando pressão sobre os resultados dos bancos e sobre os respetivos requisitos de capital. Entre dezembro de 2008 e dezembro de 2015 o rácio de crédito em incumprimento das sociedades não financeiras passou de 2,2% para 15,9%. No mesmo período, a parcela de empresas com crédito vencido aumentou 10 pontos percentuais, para 29% em dezembro de 2015.

Sistemas de alerta precoce que permitam ajudar a prever futuros incumprimentos são de extrema relevância para apoiar o processo de concessão de crédito a nível individual dos bancos, mas também, ao nível agregado, para auxiliar a análise da estabilidade financeira do sistema bancário com um todo. As notações de crédito são úteis porque permitem que os reguladores, bem como os restantes agentes no mercado, possam identificar potenciais problemas que se estejam a formar em certos grupos de empresas, definidos, por exemplo, ao nível dos setores de atividade ou dimensão. Isto é particularmente relevante num contexto onde os incentivos dos bancos em termos de reporte de informação precisa e consistente sobre as probabilidades de incumprimento foram desafiados. Por exemplo, Plosser e Santos (2014) mostram que os bancos com menores níveis de capital regulatório atribuem sistematicamente probabilidades de incumprimento inferiores do que os bancos com maiores níveis de capital regulatório. Este tipo de situação implica que dois empréstimos semelhantes concedidos à mesma empresa irão determinar diferentes requisitos de capital.

As notações de crédito são também um dado útil para testes de esforço ao setor financeiro, realizados com o objetivo de avaliar o impacto que alterações no ambiente económico podem ter sobre o desempenho do setor financeiro. Esta informação pode ser usada para estimar as perdas potenciais num determinado horizonte temporal e são, portanto, instrumentos essenciais para a gestão de risco das instituições financeiras, assim como para fins de supervisão. Para esta última finalidade, é também importante possuir um sistema de referência que permita validar os requisitos de capital de cada instituição financeira.

A existência de sistemas de avaliação de crédito independentes incentiva igualmente o investimento. As oportunidades de investimento são cada vez mais globais e diversificadas, o que dificulta substancialmente a decisão final de alocar recursos entre países e empresas. Ter ao dispor medidas sintéticas que permitam medir a capacidade de uma entidade para cumprir os seus compromissos financeiros facilita a tomada de decisão. Com efeito, é normal os investidores basearem parte das suas decisões de investimento na notação

de crédito das empresas dado que nem sempre é fácil ter acesso e analisar dados detalhados sobre cada empresa que apresenta uma oportunidade de investimento. As notações de crédito são usadas igualmente para a criação de produtos financeiros estruturados e como requisito básico para identificar os valores mobiliários que podem constituir a carteira de determinadas instituições financeiras, como por exemplo, os fundos de pensões.

A existência deste tipo de indicador tem ainda relevância para os mutuários de crédito, dado que uma boa classificação significa por norma um melhor acesso ao financiamento. Adicionalmente, os proprietários e os gestores das empresas podem usar as notações de crédito para obter uma medida objetiva da saúde financeira da empresa e também como medida de comparação com os seus competidores.

No âmbito da atual política monetária descentralizada do Eurosistema, os bancos centrais nacionais concedem diretamente liquidez às instituições de crédito residentes. A fim de proteger o Eurosistema de riscos financeiros¹, todas as operações de crédito têm como garantia ativos elegíveis que têm de cumprir elevados padrões de qualidade, definidos pelo *Eurosistem Credit Assessment Framework* (ECAAF). Os sistemas de avaliação de crédito são usados para estimar o risco de incumprimento das sociedades não financeiras, tendo uma dupla aplicação neste âmbito. Por um lado, essa avaliação determina se as instituições de crédito podem utilizar um ativo de uma determinada empresa como garantia. Por outro lado, no caso dos ativos elegíveis, a dimensão do *haircut* é definida igualmente pela notação de crédito.²

Para análise económica, as notações de crédito são particularmente úteis para avaliar o mecanismo de transmissão da política monetária e para analisar a qualidade do crédito concedido à economia através do sistema financeiro. Por exemplo, estas notações podem ser usadas para avaliar se o custo do financiamento de empresas com o mesmo nível de risco intrínseco é similar ou se existem outras variáveis que determinam o custo da dívida. Há diversas teorias que procuram explicar essas diferenças, baseadas por norma em assimetria de informação ou no nível de requisitos de capital dos bancos (ver, por exemplo, Santos e Winton 2015, e também Plosser e Santos 2014). É particularmente interessante a comparação de empresas de diferentes países da área do euro e a identificação da componente da taxa de juro que pode ser atribuída ao risco da empresa e a que se deve a outros fatores, nomeadamente problemas no mecanismo de transmissão da política monetária ou do risco

1. O colateral exigível para operações de refinanciamento inclui não só títulos de dívida mas também empréstimos a empresas não financeiras.

2. De forma a avaliar a qualidade do colateral, o Eurosistema toma em consideração informação de quadro possíveis fontes: (i) instituições externas de avaliação de crédito (IEAC); (ii) sistemas internos de avaliação de crédito dos bancos centrais nacionais (SIAC); (iii) sistemas baseados em notações de crédito internas (*IRB*, sigla em inglês); e (iv) ferramentas de notação de crédito fornecidas por terceiros (*RT*, sigla em inglês).

específico do país. Os dados utilizados pelos sistemas de avaliação de crédito são também importantes para identificar empresas com negócios viáveis mas cuja sobrevivência possa estar ameaçada devido a falta de financiamento. Esta informação pode ser usada para ajudar a definir políticas públicas de apoio que permitam solucionar problemas decorrentes de uma estrutura financeira desadequada em empresas com negócios viáveis.

Para fins estatísticos, a utilização de notações de crédito é direta. De facto, qualquer estatística baseada em informação individual de empresas pode ser apresentada por classe de risco, sendo disso exemplo a compilação de estatísticas de taxas de juro por classe de risco das empresas ou a simples repartição do total do crédito bancário por nível de risco dos mutuários.

De modo a descrever um sistema avaliação de crédito adequado às finalidades referidas anteriormente, este artigo está estruturado da seguinte forma. Em primeiro lugar, são apresentados os dados utilizados e é definido o conceito de incumprimento. Em segundo lugar, é descrita a metodologia subjacente ao sistema de avaliação de crédito, apresentando-se de seguida um exercício de calibração por forma a ajustar os resultados do modelo à escala de referência utilizada pelo Eurosistema. Posteriormente, são apresentados alguns resultados referentes às probabilidades de incumprimento estimadas e à matriz de transição entre classes de risco de crédito. Por último, apresenta-se uma conclusão da análise.

Dados

Este trabalho utiliza informação da Central de Balanços (CB) e da Central de Responsabilidades de Crédito (CRC), duas bases de dados geridas pelo Banco de Portugal. A CB contém informação económico-financeira da generalidade das empresas em Portugal obtida essencialmente através da Informação Empresarial Simplificada (IES). A CRC centraliza informação mensal sobre todas as exposições das empresas e particulares junto do setor financeiro em Portugal. Para os fins desta análise a informação da CB cobre o período 2005–2014 e a informação da CRC abrange o período 2002–2015.

Neste artigo apenas são consideradas empresas não financeiras privadas com pelo menos uma exposição junto do sector financeiro residente. Por simplificação de linguagem, serão referenciadas com o termo “empresas”. O facto de o objetivo desta análise ser estimar probabilidades de incumprimento justifica a exclusão de empresas sem empréstimos bancários. Adicionalmente, foram também excluídas as empresas com reporte incompleto ou incoerente à CB, como por exemplo são os casos de reporte de ativo total e/ou volume de negócios negativos. Ao nível da CRC, apenas são consideradas empresas com crédito efetivo, tendo-se excluído as que apenas tinham crédito renegociado e/ou abatido ao ativo. Para além disso, foram excluídas todas as empresas

cuja exposição de crédito junto do sistema financeiro (ou seja, agregada sobre todas as relações empresa-banco) fosse inferior a €10.000.

Definição de incumprimento

Uma empresa é considerada “em incumprimento” junto do sistema financeiro se a parcela de crédito em incumprimento for superior a 2,5 por cento do total de crédito. O “evento de incumprimento” ocorre quando a empresa completa três meses consecutivos em incumprimento. Diz-se que uma empresa incumpriu num determinado ano se durante esse ano ocorreu um evento de incumprimento. É possível que a mesma empresa possa ter mais do que um incumprimento durante o período de análise. No entanto, de modo a garantir que a amostra não é enviesada pela existência de empresas com incumprimento recorrente, excluimos todas as observações da empresa após o primeiro evento de incumprimento.

Apenas são consideradas empresas que ou são novas para o sistema financeiro durante o período em análise (isto é, empresas que não tiveram relações bancárias antes de 2005, possivelmente por nem sequer existirem), ou têm um historial de crédito de três anos totalmente limpo. As empresas que surgem na CRC já em incumprimento são excluídas.

Tratamento dos dados e definições das variáveis

De forma a aumentar a homogeneidade, dividimos a amostra em microempresas e o conjunto composto por todas as outras empresas (ou seja, pequenas, médias e grandes empresas). Estes dois grupos foram ainda subdivididos com base na classificação da atividade económica (CAE). Alguns setores de atividades foram agregados devido à afinidade entre eles, como foi o caso, por exemplo, da construção e do imobiliário. Em resultado deste processo obtiveram-se cinco setores de atividade distintos (indústria transformadora e extrativa; construção e imobiliário; comércio e setor primário; transportes e armazenagem; e serviços) e duas categorias para a dimensão (microempresas; todas as restantes empresas), para um total de dez conjuntos de empresas a usar nas estimações econométricas. Ver Quadro 2.

A CB dispõe de informação detalhada relativa às demonstrações financeiras das empresas não financeiras em Portugal. Para os fins desta análise foi utilizado apenas um subconjunto de variáveis. As diversas variáveis disponíveis podem ser categorizados em grupos específicos: alavancagem, rendibilidade, liquidez, estrutura de capital, dimensão e um grupo residual que corresponde a variáveis relacionadas com os rácios de balanço que não se enquadram em nenhum dos grupos previamente definidos. Todas as variáveis em nível foram redefinidas através da sua divisão pelo total do ativo, total do passivo corrente ou do passivo total,

#	Dimensão
1	Micro
2	Pequenas, médias e grandes
#	Setor de atividade
1	Indústria transformadora e extrativa
2	Construção e imobiliário
3	Comércio e setor primário
4	<i>Utilities</i> , transportes e armazenagem
5	Serviços

QUADRO 2. Classificação de empresas por dimensão e setor.

Fonte: Banco de Portugal.

Medidas de:	Variáveis
Alavancagem	Dívida financeira; Dívida bancária; Juros pagos
Rentabilidade	VAB por trabalhador; Resultados líquidos / Perdas; EBIT; <i>Cash flow</i> ; EBITDA
Liquidez	Caixa; Responsabilidades correntes
Estrutura de financiamento	Capital próprio; Ativo corrente; Ativo tangível
Dimensão	Ativo total; Idade; Volume de negócios; N.º de empregados
Outros fatores idiossincráticos	Salários; Débitos comerciais
Macroeconomia	Tx. incumprimento anual; Tx. cresc. do crédito; Tx. cresc. PIB Nominal; Tx. cresc. PIB Real

QUADRO 3. Resumo das variáveis usadas nas regressões.

Fonte: Banco de Portugal. Definições rigorosas das variáveis disponíveis a pedido.

consoante o caso. Indicadores cujo denominador possa ter valores negativos não são utilizados dado que poderiam gerar discontinuidades significativas quando o denominador está próximo de zero. Para ter em conta a possível influência do ciclo económico na probabilidade de incumprimento de uma empresa específica, foi considerado um pequeno conjunto de fatores macroeconómicos: o crescimento do PIB nominal e real, o crescimento do crédito total e a taxa de incumprimento agregada das empresas. Esta escolha foi motivada pela literatura sobre o tema; por exemplo, Figlewski *et al.* (2012) encontraram evidência de que o crescimento real do PIB e a taxa de incumprimento agregada das empresas são fatores determinantes para explicar as transições entre classes de notação de crédito. O Quadro 3 apresenta o subconjunto de variáveis da CB e os fatores macroeconómicos usados nesta análise.

Como mencionado anteriormente, as empresas com valores negativos para o total do ativo, do passivo ou do volume de negócios foram excluídas da análise. Foram também eliminadas as empresas com total de ativo, volume

de negócios ou número de empregados igual a zero. De modo a diminuir os valores de assimetria e curtose, variáveis estritamente positivas foram transformadas em logaritmos. Tendo em conta que esta transformação não é aplicável às variáveis que podem assumir valores negativos, o conjunto de variáveis foi ampliado com a classificação (ou *ranking*), em termos de cada variável e para cada observação, normalizada entre 0 e 1. As ordenações foram calculadas dentro de cada grupo ano-dimensão-setor de atividade de modo a aumentar a homogeneidade. As variáveis expressas em percentagem e os indicadores macroeconómicos foram mantidos no formato original.

Metodologia

Neste estudo desenvolvemos uma abordagem de seleção de variáveis baseada num sistema multicritério, tendo por base a metodologia definida por Imbens e Rubin (2015) na qual a seleção de variáveis explicativas é efetuada recorrendo à estimação de máxima verosimilhança. Esta metodologia seleciona as variáveis através de um processo iterativo baseado na capacidade de previsão individual de cada indicador. Uma determinada variável apenas será selecionada se a sua inclusão aumentar o poder explicativo do modelo acima de um determinado limiar. Esta abordagem é então alterada para os nossos fins específicos.

Seleção das variáveis explicativas

Começamos por estimar um modelo de base com efeitos fixos para a dimensão (excluindo o caso das microempresas) e para o setor de atividade (a um nível de desagregação de alguns subsetores). Para cada variável do conjunto inicial de N variáveis estimamos um modelo com os efeitos fixos mais essa variável. Estas regressões serão então comparadas com o modelo de base usando um teste de razão de verosimilhança (LR, de *likelihood ratio*). Em seguida o algoritmo escolhe a variável associada ao modelo com o valor de teste mais elevado, respeitando a restrição de se situar acima do valor inicial com um nível de significância de 5%, o que corresponde a um teste LR com um valor mínimo de 3,84.

O processo é então repetido, mas o modelo de referência é agora o modelo com os efeitos fixos mais a variável selecionada no passo anterior. A próxima variável será escolhida de entre as restantes $N - 1$ variáveis, sendo que a partir desta segunda etapa são impostas algumas condições adicionais de modo a lidar com potenciais problemas decorrentes da inclusão completamente automática de variáveis. Mais especificamente, são impostas as seguintes condições para que uma nova variável possa ser incluída no modelo:

1. Tem de apresentar uma correlação linear e não-linear inferior a 0,5 com qualquer uma das variáveis já presentes no modelo. Esta condição visa evitar potenciais problemas de multicolinearidade.
2. Deve ser estatisticamente significativa na nova regressão com um nível de significância mínimo de 5%, devendo o mesmo continuar a verificar-se para todas as variáveis incluídas anteriormente. Pretende-se assim evitar que na especificação final do modelo possam subsistir variáveis estatisticamente não significativas.
3. A nova especificação do modelo deve melhorar o AUROC face ao seu valor anterior³. Para além disso, deve melhorar também o critério de informação AIC. Esta condição procura evitar o potencial sobreajustamento do modelo, dado que o AIC penaliza a inclusão de variáveis adicionais.

O processo termina quando nenhuma variável adicional preenche as condições 1–3 ou, para evitar a proliferação de parâmetros, foi atingindo um máximo de dez variáveis. Com o objetivo de manter a abordagem tão simples e replicável quanto possível, foi escolhida uma especificação Logit.

Todos os dez modelos (um por cada combinação de dimensão e setor de atividade) foram estimados utilizando o total de observações existentes, abrangendo o período de 2005 a 2014 no que respeita a informação económico-financeira das empresas. Todas as variáveis explicativas pertencem ao final do ano atual t . A variável dependente é o indicador da ocorrência de um evento de incumprimento no ano seguinte $t + 1$. É de notar que quando a restrição sobre o número máximo de variáveis é removida nenhum dos dez modelos inclui mais de 13 variáveis. Adicionalmente, ao analisar a evolução do AUROC com a inclusão de cada variável adicional é possível verificar que este indicador tende a estabilizar antes da inclusão da décima variável; ver Gráfico 1.

Um resumo dos resultados

Após a aplicação aos dados da metodologia apresentada, foram feitas dez estimações de modelos Logit; o Quadro 4 apresenta alguma informação sobre eles⁴. Uma primeira observação pode ser feita analisando o ajustamento geral dos modelos aos dados, algo que pode ser avaliado através do AUROC⁵. Esses mesmos valores variam entre 0,72 e 0,84, rejeitando confortavelmente

3. O acrónimo AUROC significa *area under the Receiver Operator Characteristic*. Ver Lingo e Winkler (2008) e Wu (2008) para a definição e propriedades estocásticas desta medida sintética.

4. Na aplicação concreta não foram usadas as variáveis originais, à exceção dos casos em que as mesmas representavam rácios ou taxas de crescimento, dado que o algoritmo escolheu sempre as variáveis transformadas (em logaritmo ou classificação).

5. Para uma crítica do AUROC como medida do poder discriminante de um modelo no contexto de validação de modelos, ver Lingo e Winkler (2008).




GRÁFICO 1: AUROC em função do número de variáveis selecionadas de acordo com a metodologia definida no texto. D# indica a categoria de dimensão # e S# indica o setor de atividade #; ver Quadro 2 para mais detalhes.

Fonte: Banco de Portugal e cálculos dos autores.

a hipótese de que os modelos são equivalentes a uma classificação aleatória. Adicionalmente, a estatística de Brier para cada modelo, uma medida também para a adequação do modelo aos dados, é consideravelmente pequena. No caso do teste de Spiegelhalter (1986) aplicado a cada modelo individualmente (resultados não reportados) verifica-se que o nível de incumprimento estimado é consistente com o nível de incumprimento observado empiricamente.

Embora a metodologia utilizada implique estimar dez modelos separadamente, é possível observar várias semelhanças entre eles. O Quadro 5 apresenta um resumo das variáveis mais frequentemente escolhidas pelo algoritmo. Os diferentes modelos identificam um conjunto de variáveis mais importantes, mesmo que por vezes sejam escolhidas pequenas variantes da mesma variável: por exemplo, as medidas de liquidez dadas pelo quociente entre caixa e total do ativo ou entre caixa e ativo corrente são sempre escolhidas, ainda que nunca sejam ambas escolhidas pelo mesmo modelo.

Grupo	Obs.	Incump. ^{tos}	Tx. incump.	# variáveis	AUROC	Brier Score
D1 - S1	58063	3000	5,17%	10	0,738	0,047
D1 - S2	53543	2965	5,54%	10	0,717	0,050
D1 - S3	178178	7696	4,32%	10	0,764	0,039
D1 - S4	2681	121	4,51%	5	0,748	0,041
D1 - S5	123048	5336	4,34%	10	0,748	0,040
D2 - S1	98065	3887	3,96%	5	0,800	0,035
D2 - S2	58325	3861	6,62%	10	0,763	0,057
D2 - S3	96738	3062	3,17%	7	0,835	0,028
D2 - S4	3903	128	3,28%	5	0,836	0,030
D2 - S5	73782	2476	3,36%	10	0,798	0,031
Total	746326	32532	4,36%	n.d.	0,777	0,0393

QUADRO 4. Um resumo das estimações Logit para os dez tipos de empresas. Valores a negrito indicam que o procedimento parou ao atingir o limite de variáveis explicativas. D# indica a categoria de dimensão # e S# indica o setor de atividade #; ver Quadro 2 para mais detalhes.

Fonte: Banco de Portugal e cálculos dos autores.

Todos os modelos incluem uma medida de rendibilidade, alternando entre o rácio de *cash flow* para total do ativo e o rácio de resultados líquidos para total do ativo, para além de uma medida de liquidez. Nove dos dez modelos incluem também o custo do crédito, bem como uma medida para o peso do passivo corrente no total do ativo. Oito modelos incluem uma medida para endividamento e sete modelos uma medida do peso dos salários dos trabalhadores no total do ativo. Para sete modelos, é escolhida uma variável macroeconómica (de entre a taxa de crescimento do PIB nominal, a taxa de crescimento do total do crédito e a taxa de incumprimento agregada). Finalmente, seis modelos incluem a idade da empresa e cinco modelos incluem uma *proxy* para a produtividade da empresa medida pelo VAB por trabalhador.

Curiosamente, o peso de dívida comercial em relação ao total do passivo é selecionado cinco vezes, em todos os casos para o grupo das microempresas. Este resultado sugere que para este grupo de empresas o comportamento dos fornecedores é particularmente relevante.

Outro resultado significativo é que as variáveis que mais frequentemente são escolhidas pelo algoritmo são normalmente selecionadas em primeiro lugar, o que sugere que estas variáveis têm o maior contributo para o poder explicativo do modelo. Neste grupo destacam-se as variáveis que medem a rendibilidade da empresa, que são sempre as primeiras a ser escolhidas pelo algoritmo nos dez modelos.

Uma observação adicional relevante consiste no facto de o coeficiente de cada variável ter em cada modelo o sinal esperado, apesar de o algoritmo

Variável	# vezes selecionada	Classificação média	Sinal do coef.
r(Cash flow / Total ativo)	6	1,0	-
r(Resul. líq. / Total ativo)	4	1,0	-
r(Juros pagos / Dívida fin.)	9	3,1	+
r(Passivo corrente / Total ativo)	5	3,4	+
r(Idade)	5	4,4	-
r(Salários / Total ativo)	5	4,6	-
r(Caixa / Ativos correntes)	6	6,0	-
r(Dívida fin. / Total ativo)	5	5,6	-
log(Passivo corrente / Total ativo)	4	4,5	+
r(Caixa / Total ativo)	4	5,8	-
r(Dívida comercial / Passivo corrente)	5	7,2	+
log(Dívida fin. / Total ativo)	2	3,0	+
r(VAB por trabalhador)	5	7,8	-
Tx. cresc. PIB Nominal	3	6,3	-
Tx. cresc. crédito total	2	5,0	+
Tx. incumprimento anual	2	5,0	+
log(Capital próprio / Total ativo)	1	3,0	-
r(Dívida bancária / Total ativo)	1	4,0	+
r(N.º trabalhadores)	2	8,5	+
log(Salários / Total ativo)	2	9,0	-
log(Volume negócios)	2	9,5	-
log(Idade)	1	7,0	-
r(Ativo corrente / Total ativo)	1	10,0	-

QUADRO 5. Resultados qualitativos do procedimento de escolha de variáveis. $r(\cdot)$ representa a classificação da variável calculada para o grupo de dimensão-setor no ano corrente; $\log(\cdot)$ representa o logaritmo natural da variável. A segunda coluna contém o número de vezes que a variável é escolhida (num máximo de dez modelos). A terceira coluna apresenta a classificação média (1 corresponde a primeira escolha, 10 a décima escolha) da variável. A quarta coluna indica o sinal do coeficiente na estimação Logit do evento de incumprimento. As variáveis são ordenadas pelo produto entre o inverso do número de vezes em que a variável é escolhida e a respetiva classificação média, em ordem ascendente. D# indica a categoria de dimensão # e S# indica o setor de atividade #; ver Quadro 2 para mais detalhes.

Fonte: Banco de Portugal e cálculos dos autores.

não ter qualquer restrição a esse respeito. Para além disso, sempre que uma variável é selecionada em mais do que um modelo o sinal do coeficiente permanece o mesmo.

Calibração das classes de crédito

O próximo passo na criação de uma ferramenta de atribuição de risco de crédito é calibrar o modelo de forma a que as taxas de incumprimento observadas em cada uma das classes de crédito sejam consistentes com a taxa de incumprimento tipicamente usadas para as definir (ver Quadro 1). Este passo é normalmente necessário porque, embora a taxa de incumprimento condicional média estimada pelo modelo coincida com a

taxa de incumprimento média observada, isto pode não se verificar para diferentes grupos de empresas ou diferentes classes de risco. Um requisito básico para a calibração que se pretende implementar é que a taxa global de incumprimento seja consistente com a taxa de incumprimento condicional proveniente dos modelos estimados. Embora este requisito seja genericamente alcançado na amostra usada, uma questão pode ainda assim ser colocada: será a probabilidade de incumprimento condicional consistente também para as diferentes categorias de risco?

Para responder a esta questão, precisamos primeiro de definir o conceito de *z-score* no contexto da nossa análise. O modelo Logit usado na metodologia descrita anteriormente é caracterizado em termos de uma variável latente não observada que é depois transformada num valor entre 0 e 1 correspondente à probabilidade de incumprimento. De forma a manter a análise simples, é suficiente referir que os coeficientes β de cada um dos modelos Logit são estimados de forma a que a probabilidade de incumprimento seja, dentro do possível, representada por

$$\Pr\{\text{incump}_{t+1} = 1|x_t\} = \frac{1}{1 + e^{-x_t\beta}}$$

onde incump_{t+1} é um indicador de um evento de incumprimento no ano $t + 1$, x_t é um vetor (linha) de regressores no ano t – incluindo a constante e variáveis ao nível da empresa e eventualmente também da economia – e β é um vetor (coluna) dos coeficientes. Uma propriedade destes coeficientes faz com que a média amostral da probabilidade estimada de incumprimento (calculada pela equação anterior) seja igual à média dos valores observados para a taxa de incumprimento. O *z-score* de cada uma das observações é definido simplesmente como a estimativa da variável latente, ou seja, $z_t = x_t\beta$.

A resposta à questão anteriormente colocada é genericamente positiva. O Gráfico 2 apresenta as probabilidades de incumprimento estimadas pelo modelo (a linha a traço-ponto) assim como as taxas de incumprimento médias observadas (os pontos do gráfico). Cada ponto representa a fração de incumprimentos para grupos de empresas com *z-scores* semelhantes. Quanto mais baixo (isto é, mais negativo) for o *z-score*, mais reduzida será a probabilidade de incumprimento da empresa. Podemos verificar que a especificação Logit é uma boa representação da relação entre os *z-scores* e a taxa de incumprimento observada para os diferentes grupos de empresas ao longo de toda a distribuição de *z-scores*.

Uma forma de tentar melhorar o ajustamento da linha aos pontos é usar uma aproximação mais flexível. Embora este procedimento não seja inteiramente consistente com a estimação, consideramos este exercício um ajustamento e não algo passível de invalidar os resultados obtidos através da análise de regressão. Nesse sentido, a linha a cheio representa essa tentativa: mais especificamente, é uma curva semi-paramétrica que interpola os pontos

do gráfico. Podemos verificar que ambas as curvas (a Logit e a versão semi-paramétrica) sugerem a mesma relação, sendo que a curva semi-paramétrica se mantém ligeiramente acima da curva Logit para z -scores muito negativos. Isto sugere que, para este intervalo de z -scores, a curva semi-paramétrica será mais conservadora a atribuir uma probabilidade de incumprimento às empresas.




GRÁFICO 2: Probabilidades de incumprimento das empresas. Cada ponto representa a taxa de incumprimento de conjuntos de empresas com z -scores semelhantes. Estão também representados os limites superiores de taxas de incumprimento de cada *Credit Quality Step* tal como definidos pelo Eurosistema.

Fonte: Banco de Portugal e cálculos dos autores.

De seguida detalhamos com mais pormenor o procedimento usado para ajustar a curva semi-paramétrica aos pontos, sendo que o leitor menos interessado no detalhe matemático pode confortavelmente saltar para a secção seguinte.

Ajustando uma curva aos pontos

Os pontos do Gráfico 2 representam a probabilidade de incumprimento empírica para grupos de observações na amostra. Cada ponto no gráfico é retirado do conjunto de pontos $S^n = \{(\hat{d}_q^n, \hat{z}_q^n)\}_{q=1, \dots, Q^n}$. Estes pontos foram obtidos da seguinte forma. Em primeiro lugar, colocámos todos os z -scores por ordem crescente (estes são normalizados e podem ser comparados entre

os diferentes grupos de empresas) na amostra. Em seguida, identificaram-se os primeiros n incumprimentos e definiu-se r_1^n como o número de ordem da observação com o n -ésimo incumprimento. De seguida, agruparam-se essas observações no conjunto $A_1^n = \{z_1, \dots, z_{r_1^n}\}$. Calculou-se então o rácio $\hat{d}_1^n = \frac{n}{\#A_1^n}$ e definiu-se \hat{z}_1^n como a mediana do conjunto A_1^n . Repetiu-se este procedimento para o grupo seguinte de n incumprimentos, construindo-se assim o conjunto $A_2^n = \{z_{r_1^n+1}, \dots, z_{r_2^n}\}$, a taxa de incumprimento $\hat{d}_2^n = \frac{n}{\#A_2^n}$ e o z -score mediano \hat{z}_2^n . Este processo foi repetido sucessivamente até se percorrerem todas as observações, totalizando um total de Q^n conjuntos de taxas de incumprimento empíricas e respetivos z -scores. Importa realçar que, para todo q , se tem $\hat{z}_{q-1}^n \leq \hat{z}_q^n \leq \hat{z}_{q+1}^n$, isto é, esses conjuntos estão também eles ordenados em ordem ascendente em termos de z -scores, embora não necessariamente em termos de probabilidades de incumprimento. Nem todos os pontos foram representados no Gráfico 2, tendo sido usada apenas uma sua amostra representativa.

Uma palavra sobre o processo de escolha de n . Se este número for muito pequeno, o desvio-padrão da probabilidade empírica estimada será relativamente elevado. De forma a tornar isto claro, assumamos que o evento de crédito segue uma distribuição binomial dentro do conjunto A_q^n , e use-se o estimador \hat{d}_q^n para a probabilidade de incumprimento. Uma estimativa do desvio-padrão de \hat{d}_q^n será

$$\sqrt{\frac{\hat{d}_q^n(1 - \hat{d}_q^n)}{\#A_q^n - 1}}$$

que decresce com $\#A_q^n$. Nas nossas simulações foi usado $n = 23$ porque, dada a escassez relativa de z -scores muito negativos (associados a probabilidades de incumprimento relativamente baixas), pretendíamos obter estimativas significativas para as taxas de incumprimento, mesmo para classes de crédito elevadas. Com esta escolha acabámos por ter Q^{23} próximo de 1400. Mais à frente iremos abordar a significância estatística destas estimativas decorrentes desta escolha. A robustez geral dos resultados desta análise relativamente ao valor de n é realizada noutra local. Para comodidade iremos simplificar a notação e retirar n das expressões que se seguem.

De forma a manter a análise tão simples quanto possível, ajustou-se uma *smoothing spline* aos pontos do gráfico. A *smoothing spline* é uma curva semi-paramétrica que se aproxima do conjunto de pontos do gráfico, e que ao mesmo tempo penaliza a ocorrência de pontos de inflexão ao longo de toda a curva. Escolheu-se a seguinte especificação:

$$s(\cdot) = \arg \min_p \sum_{q=1}^Q (\log(\hat{d}_q) - s(\hat{z}_q))^2 + (1-p) \int_{\hat{z}_1}^{\hat{z}_Q} (s''(z))^2 dz.$$

Nesta formulação, a função $s : [\hat{z}_1, \hat{z}_Q] \rightarrow]-\infty, 0]$ é uma *spline* cúbica definida para o conjunto de pontos de S . A *spline* cúbica é um conjunto de polinómios

cúbicos definidos em intervalos e “colados” nos z -scores distintos contidos em S . Por construção, $s(\cdot)$ possui segunda derivada contínua $s''(\cdot)$ em todos os pontos. O parâmetro p controla a suavidade da curva de interpolação. Se p for próximo de 1, obtém-se a chamada interpolação cúbica natural, que passa por todos os pontos de⁶ S . Se p for próximo de 0, a penalização da segunda derivada garante que a solução será uma interpolação linear, que tem segunda derivada nula.

A *smoothing spline* com $p = 0,3$ encontra-se representada no Gráfico 2 como a linha a cheio.

No Gráfico 2 verifica-se claramente que a probabilidade de incumprimento empírica será ainda uma medida algo “ruidosa”: embora cada ponto represente o z -score mediano de um conjunto de observações conducente a um determinado número de incumprimentos (23 incumprimentos), é possível ter grupos com empresas muito semelhantes – no sentido em que possuem z -scores muito próximos – e ainda assim registarem-se taxas de incumprimentos relativamente díspares entre esses grupos de empresas. Essa preocupação pode ser respondido olhando para o desempenho dos modelos em termos de AUROC, que foi apresentado anteriormente. Em todo o caso, a forma genérica da nuvem de pontos diz-nos que o quadro analítico capta razoavelmente bem a probabilidade de incumprimento das empresas: um modelo aleatório iria gerar uma nuvem de pontos ao longo de uma linha horizontal. O gráfico implica assim que, mesmo quando podem ser obtidos AUROC elevados, o evento de crédito é ainda um evento muito incerto.

Definição de classes de crédito

O procedimento escolhido para categorizar empresas de acordo com as classes de crédito consiste (i) na obtenção de valores de referência para probabilidade de incumprimento de fontes externas, seguida (ii) da escolha dos limiares em função do z -score para as diferentes classes de risco de crédito e finalmente (iii) a confirmação, *a posteriori*, de que as probabilidades de incumprimento observadas para a amostra são consistente com as probabilidades usadas para as classes de crédito. Adicionalmente, apresentamos uma análise mais detalhada das transições de empresas entre diferentes classes de crédito e para incumprimento.

Focando a análise na calibração das classes de risco de crédito, as linhas tracejadas horizontais no Gráfico 2 representam o limite superior das classes de crédito de acordo com o sistema de classes de crédito usado pelo Eurosistema (ver Quadro 1). Por exemplo, a classe 3 corresponde à classe de crédito de pior qualidade para a qual, no quadro regular da política monetária,

6. Tecnicamente, se existirem pontos em S com o mesmo z -score, a interpolação natural passa pela média dos logaritmos das taxas de incumprimento por entre todos os pontos com o mesmo z -score.

os empréstimos das empresas podem ainda ser usados como colateral pelas instituições financeiras para fins de operações de refinanciamento junto do Eurosistema. Ao invés de usarmos a curva Logit para calcular as probabilidades condicionais – que é representada no gráfico pela linha a traço-ponto – adotámos a versão semi-paramétrica e ajustamos uma *smoothing spline* a este grupo de pontos. Foram efetuados exercícios adicionais de robustez no que diz respeito aos parâmetros da *smoothing spline* que não são apresentados neste artigo.

Comparando a curva semi-paramétrica com a curva Logit, no Gráfico 2, verificamos que, para as probabilidades de incumprimento estimadas mais reduzidas de que possuímos observações, a *smoothing spline* é mais conservadora na classificação de classe de crédito, sendo a curva Logit mais conservadora para os *z-scores* localizados na zona intermédia. Para probabilidades de incumprimento um pouco superiores as duas curvas são aproximadamente equivalentes, enquanto que para probabilidades de incumprimento estimadas mais altas a curva Logit é novamente mais conservadora do que a *smoothing spline*.

A estratégia seguida nesta secção será usar as intersecções da *smoothing spline* com o limite superior das classes de crédito para definir limites em termos de *z-scores*⁷. Estes valores podem ser observados no Gráfico 3, onde também apresentamos o limite superior em termos de probabilidade dentro de cada classe.

Importa, no entanto, referir dois aspetos. Por um lado, verifica-se claramente que mesmo com esta estratégia é necessária uma avaliação pós-estimação. Isto verifica-se já que, embora os novos limites das classes sejam definidos em função dos *z-scores*, se as taxas de incumprimentos observadas forem demasiado incertas estas não terão poder discriminante relativamente às classes adjacentes. O facto de os pontos representarem uma função relativamente harmoniosa da probabilidade de incumprimento em termos dos *z-scores* sugere uma razoável capacidade do método de classificação em gerar resultados consistentes.

Por outro lado, não nos é possível classificar empresas em classes de crédito com probabilidades de incumprimento abaixo de um certo limiar. Isto é devido à escassez de observações classes de menor risco. Por exemplo, o limite superior da probabilidade de incumprimento admissível para *Credit Quality Step 1* seria 0,03% ao longo de um ano⁸. Tal probabilidade sugere que seriam necessárias aproximadamente 67 mil observações classificadas nessa classe de forma a ser expectável observar cerca de 20 incumprimentos⁹. Dado

7. Para a classe 1 & 2, a intersecção foi extrapolada. Ver secção seguinte.

8. Esta classe seria genericamente equivalente a um rating de AA- ou superior (no caso da Fitch e da Standard & Poors) ou Aa3 ou superior (para a Moody's).

9. Isto é, $20 \times \frac{1}{0,0003} \approx 67.000$ observações.




GRÁFICO 3: Limiares para classes de crédito em termos de *z-score* definidos de acordo com o texto.

Fonte: BCE, Banco de Portugal e cálculos dos autores.

que não nos é possível classificar este número de empresas nesta classe de crédito, não nos é igualmente possível garantir que estas empresas tenham efetivamente uma probabilidade de incumprimento compatível com classe de nível 1. Mesmo no caso de reduzirmos o número de incumprimentos expectáveis para, digamos, 5, seriam mesmo assim necessárias cerca de 17 mil observações. Na prática, para a nossa amostra verificamos que são justificáveis limites até à classe de nível 2, uma vez que podemos estimar taxas de incumprimento de forma consistente. Utilizando a notação anterior, podemos confirmar este facto ao verificarmos que $\hat{d}_1^{23} = \frac{23}{11486} = 0,002$, ou seja, os primeiros 23 incumprimentos ocorrem para os 11.486 *z-scores* mais negativos. Esta taxa de incumprimento é significativamente inferior ao limite superior da classe de crédito de nível 3 e acima do limite superior da classe de crédito de nível¹⁰ 2. Ao analisarmos a curva ajustada do Gráfico 2, concluímos que a classe 3 pode ser usada na extrapolação de uma classe de nível superior. Por esta razão, agregamos as classes de crédito de níveis 1 e 2 na classe designada por “1 & 2”. No Gráfico 4 apresentamos as taxas de incumprimento

10. Assumindo uma distribuição binomial, os limites inferior e superior do intervalo de confiança a 90% para \hat{d}_1^{23} são 0,13% e 0,27%, respetivamente.

observadas para cada classe usando os limites apresentados no Gráfico 3. São também apresentados os limites superiores das probabilidades de incumprimento para cada classe de crédito. Dado estarmos a usar um procedimento conservador no cálculo dos limites, podemos verificar que, à exceção da classe 1 & 2, as taxas de incumprimento observadas são inferiores ao limite superior de cada classe. Adicionalmente, assumindo uma distribuição binomial dentro de cada classe¹¹, o limite inferior do intervalo de confiança a 90% da taxa de incumprimento encontra-se acima do limite superior da classe de crédito adjacente com melhor qualidade (à esquerda), enquanto o limite superior do intervalo se encontra abaixo do limite superior da própria classe.

Classes com poucas observações

A classe 1 & 2 merece uma especial atenção. De uma amostra com cerca de 740 mil observações desde 2005 até 2014, a metodologia descrita anteriormente permite-nos classificar 1177 observações nesta classe. Destas, apenas 2 observações tiveram um evento de incumprimento de crédito. A significância estatística da taxa de incumprimento empírica é, portanto, muito baixa: um evento de incumprimento adicional altera consideravelmente a taxa de incumprimento observada para esta classe. No Gráfico 4 este facto pode ser verificado olhando para a amplitude do intervalo de confiança a 90%, cujo limite inferior é 0 e o limite superior é 0,35%. Isto também significa que não é possível rejeitar a hipótese nula de que, assumindo uma distribuição binomial, a probabilidade de incumprimento real seja inferior a 0,1%.

Em conclusão, será de esperar que o modelo seja capaz de distinguir de forma consistente as empresas em termos das classes de crédito, ao mesmo tempo que se define a melhor classe agregando todas as empresas maior qualidade de crédito. O poder discriminante do modelo é afetado pelo número de observações em cada classe; consideramos justificável classificar empresas até à classe 2. Na secção seguinte, apresentamos uma análise das transições de empresas entre as diferentes classes e para incumprimento.

Alguns resultados

De seguida apresentamos alguns dos resultados da aplicação deste sistema de classificação do crédito aos nossos dados. Os resultados são consistentes com a observação do Gráfico 2 de que os *z-scores* parecem ser um bom mecanismo de diferenciação das empresas no que diz respeito à propensão para o incumprimento.

11. De acordo com uma distribuição binomial, a taxa de incumprimento observada de uma dada classe é o estimador de máxima verosimilhança da taxa de incumprimento.

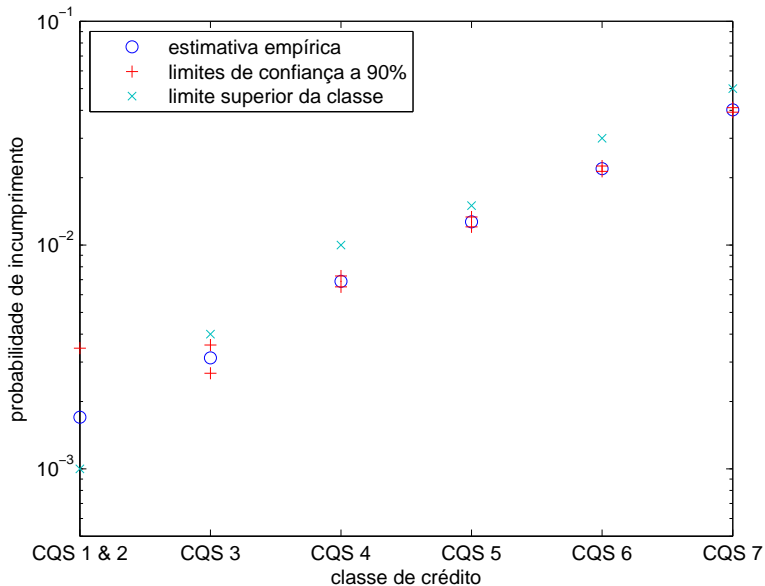


GRÁFICO 4: Probabilidades de incumprimento por classe de crédito utilizando os limiares em termos de *z-score* definidos de acordo com o texto. Os intervalos de confiança são estimados admitindo que em cada classe o evento de incumprimento obedece a uma distribuição binomial. Estão também representados por linhas horizontais a tracejado os limites superiores de taxas de incumprimento de cada *Credit Quality Step* tal como definidos pelo Eurosistema.

Fonte: BCE, Banco de Portugal e cálculos dos autores.

Dinâmica do risco de crédito

As tabelas de transição são uma forma útil de caracterizar a dinâmica das empresas entre as diferentes classes de crédito e para o incumprimento. Tipicamente, estas tabelas apresentam a probabilidade da empresa se “deslocar” para uma classe de crédito específica ou para incumprimento, condicional à classe de crédito atual. O Quadro 6 apresenta algumas estatísticas descritivas genéricas da amostra, incluindo as taxas de incumprimento observadas por classe de crédito, assim como as saídas da amostra sem a ocorrência de incumprimento.

Em geral, verifica-se que as taxas de incumprimento em todas as classes variam consideravelmente, estando, no entanto, próximas tanto dos valores previstos pelo modelo como do limite superior da respetiva classe (Gráfico 4). A classe 8 é a mais prevalente, ao passo que a classe 1 & 2 é a menos numerosa, contabilizando apenas 0,16% do total das observações, como seria de esperar pelos resultados anteriores. Mais uma vez, o teste de Spiegelhalter (1986) aplicado a cada uma das classes não nos permite rejeitar (à exceção da classe

8) a hipótese nula de que as probabilidades de incumprimento estimadas pelo modelo são iguais à verdadeira, mas desconhecida, probabilidade de incumprimento da empresa¹².

Relativamente às taxas de saída da amostra sem a ocorrência de incumprimento, os valores variam entre 11% e 18%, com uma taxa média de 13,8%. Estas transições são definidas como saídas permanentes da amostra sem que ocorra um evento de crédito, e podem ser motivados por qualquer dos seguintes eventos: (i) saída de atividade devido a fusão, aquisição ou extinção formal; (ii) todos os empréstimos da empresa foram amortizados; (iii) pelo menos um dos regressores selecionados para o modelo Logit não foi reportado pela empresa. Importa referir que os incumprimentos podem ser detetados mesmo que a empresa deixe de reportar informação para a CB dado que os bancos mantêm a obrigatoriedade de reportar qualquer empréstimo em incumprimento por empresas legalmente existentes. Estes números comparam favoravelmente com análises equivalentes na literatura. Por exemplo, Figlewski *et al.* (2012) reportam que, de uma amostra de cerca de 13.000 observações, a taxa de saída é de 33%.

Ao longo do tempo, as probabilidades de incumprimento estimadas pelo modelo ajustam-se razoavelmente às taxas de incumprimento observadas. Uma exceção a este padrão ocorreu em 2009, onde as taxas de incumprimento observadas foram consideravelmente superiores ao que a respetiva classe de risco sugeriria. No entanto, este fenómeno aconteceu também noutros países. Ver, por exemplo, o Gráfico 14 de Vazza e Kraemer (2015). No Quadro 7 este fenómeno pode ser verificado pelas diferenças entre as taxas de incumprimento observadas no ano t e os valores estimados no ano $t - 1$ para o ano t . Podemos verificar que a maior parte da variação provém da classe de maior risco, onde os setores da construção e agências imobiliárias, assim como as microempresas, estão sobre-representadas (ver o Quadro 9 mais adiante).

O Quadro 8 apresenta a tabela de transição para o conjunto das empresas que se mantêm na amostra de um ano para o outro sem a ocorrência de um evento de incumprimento. O quadro mostra que em 3 das 7 classes a maioria das empresas permanece na mesma classe de crédito. Observa-se igualmente que a larga maioria das empresas ora permanece na mesma classe de crédito, ora transita para a categoria adjacente, quer superior quer inferior. Adicionalmente, é possível verificar que as empresas apresentam uma maior probabilidade de sofrer uma redução na classe de crédito do que ocorrer o inverso, à exceção da classe 8 por razões óbvias.

A estrutura markoviana da matriz permite-nos calcular a distribuição de longo prazo para todas as classes de crédito (conhecida pela distribuição “ergódica”). Esta distribuição seria a distribuição prevalente num futuro

12. Para a classe 8 de facto rejeita-se a hipótese nula com 5% de significância estatística. A taxa de incumprimento média estimada pelo modelo é de 10,0% ao passo que a correspondente taxa observada é de 10,3%. Ver o Quadro 6.

CQS	Saídas	Taxa de incumprimento			Proporção no total da amostra
		Observada	Estimada	Limite superior	
1 & 2	16,4	0,17	0,10	0,10	0,16
3	11,1	0,31	0,28	0,40	5,5
4	11,6	0,69	0,69	1,00	16,7
5	11,8	1,27	1,24	1,50	11,1
6	12,4	2,20	2,17	3,00	21,8
7	13,1	4,02	3,91	5,00	16,0
8	17,6	10,3	10,00	100	28,8
Total da amostra	13,8	4,36	4,25	<i>n.d.</i>	100

QUADRO 6. Taxas de incumprimento estimadas e observadas e taxas de saída da amostra sem evento de crédito, por classe de risco de crédito. As taxas de incumprimento estimadas têm implícita a metodologia semi-paramétrica. Todos os valores em percentagem. A taxa de incumprimento estimada para a classe CQS 1 & 2 é definida como o limite superior da classe.

Fonte: Banco de Portugal e cálculos dos autores.

CQS	Tx. incump.	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	Total
1 & 2	Estimada	0,10	0,10	0,10	0,10	0,10	0,10	0,10	0,10	0,10	0,10	0,10
	Observada	0,00	1,75	0,00	0,00	0,72	0,00	0,00	0,00	0,00	0,00	0,17
3	Estimada	0,29	0,28	0,29	0,28	0,28	0,28	0,28	0,28	0,28	0,28	0,28
	Observada	0,16	0,30	0,33	0,78	0,17	0,27	0,42	0,22	0,26	0,39	0,31
4	Estimada	0,70	0,70	0,70	0,70	0,69	0,69	0,69	0,69	0,69	0,69	0,69
	Observada	0,48	0,51	0,64	0,87	0,42	0,77	1,13	0,77	0,70	0,46	0,69
5	Estimada	1,24	1,24	1,24	1,24	1,24	1,24	1,24	1,24	1,24	1,24	1,24
	Observada	0,82	1,00	1,46	1,82	1,05	1,59	1,89	1,34	1,02	0,66	1,27
6	Estimada	2,17	2,17	2,18	2,18	2,18	2,17	2,17	2,17	2,16	2,16	2,17
	Observada	1,35	1,84	2,41	3,33	1,70	2,54	3,40	2,21	1,68	1,42	2,20
7	Estimated	3,90	3,90	3,91	3,91	3,91	3,91	3,90	3,92	3,90	3,89	3,91
	Observed	2,61	3,56	4,64	6,09	2,99	4,51	5,86	3,99	3,30	2,35	4,02
8	Estimada	9,06	9,20	9,32	9,52	10,30	10,25	10,62	10,95	10,20	9,78	10,04
	Observada	6,57	7,99	10,43	14,44	8,09	11,00	15,29	11,32	8,59	6,42	10,31
Total	Estimada	3,77	3,91	4,03	4,30	4,64	4,25	4,59	4,82	4,13	3,75	4,25
	Observada	2,63	3,40	4,54	6,53	3,62	4,68	6,74	4,98	3,47	2,43	4,36

QUADRO 7. Taxas de incumprimento observadas e estimadas pelo modelo, ao longo do tempo e por classe de crédito. As taxas de incumprimento estimadas têm implícita a metodologia semi-paramétrica. Todos os valores em percentagem. A taxa de incumprimento estimada para a classe CQS 1 & 2 é definida como o limite superior da classe.

Fonte: Banco de Portugal e cálculos dos autores.

CQS no ano t	CQS no ano t+1						
	1 & 2	3	4	5	6	7	8
1 & 2	36,5	55,9	5,9	0,7	0,8		0,1
3	1,5	56,5	32,0	4,5	3,6	1,1	0,8
4	0,0	10,7	51,3	17,3	13,7	4,1	2,8
5	0,0	2,0	25,8	26,1	30,6	9,3	6,2
6	0,0	0,8	9,4	14,4	40,2	20,5	14,7
7		0,3	3,5	5,3	24,6	31,8	34,4
8		0,1	1,4	2,2	9,1	16,0	71,2

QUADRO 8. Transições entre diferentes classes de risco de crédito, condicionais à empresa estar incluída na amostra em dois anos consecutivos e não ter registado um evento de crédito. Cada linha soma 100 por cento. Todos os valores em percentagem.

Fonte: Banco de Portugal e cálculos dos autores.

longínquo no caso de as taxas de entrada e saída de empresas na amostra serem as verificadas na nossa amostra. Observa-se que tal distribuição é muito semelhante à registada no Quadro 4. Este resultado sugere que a amostra utilizada é uma representação razoável da dinâmica de longo prazo das empresas nas diferentes classes de crédito.

É importante notar a reduzida persistência de classes de crédito que provém desta ferramenta. A persistência média de uma empresa numa mesma classe é muito inferior à persistência observada nos ratings provenientes de agências de notação do risco. Por exemplo, Vazza e Kraemer (2015) documentam que, de entre 7 categorias de crédito, a fração de empresas a permanecer na mesma categoria é de 87%; o número comparável na nossa amostra é de 45%. Existem, no entanto, pelo menos duas razões para este facto.

Por um lado, as agências de notação do risco tipicamente produzem notações para empresas relativamente grandes, com grandes incentivos em obterem essa classificação, enquanto no nosso caso todas as empresas são incluídas *a priori* na análise. Adicionalmente, várias opções estratégicas podem enviesar os valores de persistência obtidos. Ao passo que as agências de notação do risco seguem geralmente empresas mesmo quando estas já não são notadas de forma a detetar eventuais incumprimentos, as empresas que num dado momento possuem notações de risco podem ter o incentivo em deixar de obter tal notação no caso de suspeitarem que irão sofrer uma redução na classificação. As outras duas possibilidades – classificação inalterada ou melhorada – não produzem incentivos tão fortes. Este forte enviesamento das amostras estáticas das agências de risco, embora não afetem as transições para incumprimento – dado que as classificações são condicionais à informação contabilística existente – tendem a promover notações com persistência mais elevada do que uma ferramenta de notação que potencialmente inclui todas as empresas.

Por outro lado, as agências de notação do risco e outros sistemas de classificação do risco (como por exemplo o SIAC do Banco de Portugal, que analisa atualmente sobretudo grandes empresas portuguesas) tipicamente incluem analistas dedicados exclusivamente à atribuição de notações de risco que possuem uma autonomia considerável no ajuste das classificações provenientes dos modelos. Este fator poderá igualmente potenciar a persistência das notações, já que o analista poderá ter alguma relutância em alterar a classe de crédito atribuída a uma empresa que tenha uma probabilidade de incumprimento ligeiramente fora do intervalo da notação atribuída anteriormente. Tais ajustamentos não ocorrem na nossa metodologia, o que faz com que pequenas alterações na probabilidade de incumprimento estimada provoquem alterações de classe de risco para aquelas empresas que se encontram próximas dos limiares.

O Quadro 9 apresenta probabilidades de incumprimento estimadas juntamente com probabilidades de incumprimento empíricas, desagregadas por setor de atividade e por dimensão de empresa, assim como a proporção de observações de cada classe de crédito para cada grupo. O quadro mostra que a construção e o imobiliário (setor de atividade 2) registam uma probabilidade de incumprimento média particularmente elevada quando comparada com os outros setores de atividade. Este resultado verifica-se na comparação quer em termos das probabilidades de incumprimento estimadas e empíricas, quer em termos da proporção de observações em cada classe de crédito. Em particular, neste setor de atividade a proporção de observações na classe 8 é mais do dobro do que para qualquer outra classe de crédito.

As microempresas (dimensão 1) são também classificadas como relativamente mais arriscadas, sendo que nenhuma microempresa é classificada como pertencendo à classe 1 & 2, enquanto cerca de 74% das empresas desta dimensão estão concentradas nas três piores classes de crédito. Em contraste, somente 57% das empresas maiores (dimensão 2) são classificadas nas três piores classes de crédito.

O quadro mostra ainda que os cinco setores de atividade estão genericamente enviesados para classes de crédito de maior risco, particularmente as classes 6 e 8.

Validação adicional

Está fora do objetivo deste artigo apresentar uma caracterização detalhada da performance fora da amostra da metodologia usada. Para uma abordagem simples a este tópico, o leitor mais interessado poderá ver, por exemplo, Wu (2008). Aussenegg *et al.* (2011) e Coppens *et al.* (2016), bem como as referências constantes nestes artigos, fornecem informação mais aprofundada.

CQS	Estatística	Setor de atividade					Dimensão		Total
		1	2	3	4	5	1	2	
1 & 2	Tx. incump. estimada	0,10		0,10	0,10	0,10		0,10	0,10
	Tx. incump. observada	0,00		0,18	0,00	0,00		0,17	0,17
	<i>Proporção de obs.</i>	0,02		0,40	0,70	0,00		0,36	0,16
3	Tx. incump. estimada	0,29	0,34	0,27	0,26	0,31	0,33	0,27	0,28
	Tx. incump. observada	0,40	1,38	0,30	0,00	0,19	0,29	0,32	0,31
	<i>Proporção de obs.</i>	5,89	0,45	8,61	12,56	3,56	1,33	10,79	5,52
4	Tx. incump. estimada	0,69	0,74	0,68	0,68	0,70	0,72	0,67	0,69
	Tx. incump. observada	0,68	0,94	0,75	0,79	0,56	0,70	0,68	0,69
	<i>Proporção de obs.</i>	17,45	6,48	19,12	19,33	18,41	13,10	21,20	16,69
5	Tx. incump. estimada	1,24	1,25	1,24	1,24	1,24	1,24	1,24	1,24
	Tx. incump. observada	1,44	1,45	1,25	0,56	1,14	1,24	1,31	1,27
	<i>Proporção de obs.</i>	10,81	7,72	11,44	10,75	12,72	11,24	10,88	11,08
6	Tx. incump. estimada	2,17	2,22	2,16	2,16	2,16	2,18	2,16	2,17
	Tx. incump. observada	2,24	2,25	2,10	2,22	2,26	2,21	2,17	2,20
	<i>Proporção de obs.</i>	21,02	21,73	21,19	18,45	23,39	24,15	18,83	21,79
7	Tx. incump. estimada	3,91	3,94	3,89	3,91	3,89	3,91	3,90	3,91
	Tx. incump. observada	3,89	3,76	3,98	5,28	4,32	4,11	3,86	4,02
	<i>Proporção de obs.</i>	15,52	20,40	14,67	12,65	15,86	18,54	12,82	16,00
8	Tx. incump. estimada	10,15	10,47	10,12	9,83	9,45	9,54	10,83	10,00
	Tx. incump. observada	10,37	10,80	10,47	9,75	9,59	9,71	11,26	10,31
	<i>Proporção de obs.</i>	29,29	43,22	24,56	25,55	26,06	31,64	25,12	28,75
Total	Tx. incump. estimada	4,30	5,96	3,81	3,70	3,88	4,51	3,93	4,24
	Tx. incump. observada	4,41	6,10	3,91	3,78	3,97	4,60	4,05	4,36
	<i>Proporção de obs.</i>	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

QUADRO 9. Estimativas do modelo e taxas de incumprimento observadas para diferentes conjuntos de empresas. As taxas de incumprimento estimadas têm implícita a metodologia semi-paramétrica. Todos os valores em percentagem. A taxa de incumprimento estimada para a classe CQS 1 & 2 é definida como o limite superior da classe.

Fonte: Banco de Portugal e cálculos dos autores.

Conclusão

O objetivo deste artigo é apresentar uma metodologia para avaliar a qualidade creditícia das empresas não financeiras portuguesas através da estimação da probabilidade de uma empresa ter um evento de incumprimento significativo face ao sistema financeiro durante o ano seguinte. O resultado do modelo é mapeado para uma escala onde as empresas são agrupadas em classes homogêneas de risco, originando assim um indicador sintético da capacidade da empresa em cumprir com as suas obrigações financeiras.

Ao cruzar a informação das demonstrações financeiras de 2005 a 2014 com a informação da central de responsabilidades de crédito de 2002 a 2015, foi possível estimar modelos para dez conjuntos de empresas com bom poder explicativo em termos do risco de incumprimento. Com exceção da

classe 8, as probabilidades de incumprimento estimadas pelo modelo não são estatisticamente diferentes das probabilidades de incumprimento observadas.

Os resultados mostram que as empresas estão concentradas em classes de risco mais elevado, com alguns dos conjuntos considerados, definidos em termos de setor de atividade e dimensão da empresa, não representados na classe de risco mais baixo. Como esperado, as microempresas têm, em média, uma probabilidade de incumprimento estimada e observada mais elevada do que empresas de maior dimensão. Quando comparado com os restantes setores de atividade, o setor da construção e imobiliário apresentam também taxas de incumprimento elevadas.

No que diz respeito à dinâmica implícita na tabela de transição entre classes de risco, verifica-se que, de um ano para o ano seguinte, a maioria das empresas permanece na mesma classe de risco ou migra para uma classe adjacente. A tabela de transição sugere igualmente que este modelo é uma boa representação da distribuição de risco de longo prazo do setor não financeiro português.

Finalmente, é importante observar que os dados disponíveis não permitem classificar as empresas além de uma certa qualidade de crédito. Isto deve-se à escassez de observações para as classes de menor risco. Para uma classificação mais fina entre as classes de menor risco será necessário incluir analistas profissionais no processo e, talvez, recorrer a modelos mais estruturais de incumprimento, em oposição a abordagens estatísticas como a que se seguiu neste trabalho.

Referências

- Aussenegg, Wolfgang, Florian Resch, e Gerhard Winkler (2011). "Pitfalls and remedies in testing the calibration quality of rating systems." *Journal of Banking and Finance*, 35(3), 698–708.
- Coppens, François, Fernando González, e Gerhard Winkler (2007). "The performance of credit rating systems in the assessment of collateral used in Eurosystem monetary policy operations." Working Paper 118, National Bank of Belgium.
- Coppens, François, Manuel Mayer, Laurent Millischer, Florian Resch, Stephan Sauer, e Klaas Schulze (2016). "Advances in multivariate back-testing for credit risk underestimation." Working Paper 1885, European Central Bank.
- ECB (2015). "Questions and answers on the compilation of the static pool for performance monitoring in the Eurosystem Credit Assessment Framework (ECAAF)." Available online.
- Figlewski, Stephen, Halina Frydman, e Weijian Liang (2012). "Modeling the effect of macroeconomic factors on corporate default and credit rating transitions." *International Review of Economics and Finance*, 21(1), 87–105.

- Imbens, Guido W. e Donald B. Rubin (2015). *Causal inference in statistics, social, and biomedical sciences*. Cambridge University Press.
- Lingo, Manuel e Gerhard Winkler (2008). "Discriminatory power: an obsolete validation criterion?" *Journal of Risk Model Validation*, 2(1), 45–72.
- Martinho, Ricardo e António Antunes (2012). "A Scoring Model For Portuguese Non-Financial Enterprises." In *Financial Stability Report*, pp. 111–124. Banco de Portugal.
- Plosser, Matthew C. e João Santos (2014). "Banks' incentives and the quality of internal risk models." Staff Report 704, Federal Reserve Bank of New York.
- Santos, João e Andrew Winton (2015). "Bank capital, borrower power, and loan rates." Mimeo.
- Spiegelhalter, David J. (1986). "Probabilistic prediction in patient management and clinical trials." *Statistics in Medicine*, 5, 421–433.
- Vazza, Diane e Nick W. Kraemer (2015). "2014 Annual Global Corporate Default Study And Rating Transitions." Ratings direct, Standard & Poor's Rating Services.
- Wu, Xuezheng (2008). *Credit Scoring Model Validation*. Master's thesis, University of Amsterdam, Korteweg-de Vries Institute for Mathematics.