

博士論文

衛星データと深層学習を活用した農業保険開発の研究

(A study on development of agricultural insurance using
satellite data and deep learning)

主査	柴崎	亮介	教授
副査	二宮	正士	教授
副査	竹内	渉	准教授
副査	布施	孝志	准教授
副査	川崎	昭如	准教授

桑田 賢太郎

東京大学大学院 工学系研究科 社会基盤専攻

2016年8月

論文要旨

2050年の世界人口は、96億人に達するといわれており、2015年時点の約70億人から、およそ28%も増加すると予測されている。この増加の大部分には、アジアやサハラ以南アフリカの人口増加が寄与すると考えられており、食料需要を満たすためには現時点の穀物生産量の約1.6倍の増加が必要といわれている。穀物生産の安定化と増加が望まれている一方で、世界各地で気候災害による農業セクターへの甚大な被害が発生している。世界を代表する穀倉地帯として重要な役割を担うアメリカでは、2012年に歴史的な大干ばつが発生し、アメリカ本土のおよそ65%が被害を受けたとされている。400億ドルの損失が発生したとされ、その大部分が農業分野によるものであった。その他にも、大規模な台風や洪水などの気候災害が、アジアやアフリカなどでも頻発し、国家レベルの損失を与えている。このような天候リスクを軽減するため、農業保険が注目されている。

農業保険は、災害などで農作物が損害を受けた場合、その損失を補填し、農家の収入を保証するものである。世界の市場規模は、保険料ベースで約3兆円といわれており、大半をアメリカとカナダが占め、中国で急激に拡大している。アジアやアフリカ諸国でも導入が期待され、今後も成長市場であるといわれている。農業保険は、従来型とインデックス型に分類される。従来型は、調査員が被害を査定することで保険金を支払う保険であり、モラルハザードや逆選択、運用に要する高いコストが課題として考えられている。インデックス型は、従来型の課題を改善するものとして開発され、気象観測ステーションなどで観測される気象データをインデックスとし、ある条件を満たした際に保険金が自動的に支払われる保険である。しかし、インデックス型は、ベースリスクという支払われた保険金と実際の損失額が乖離するリスクが大きな課題とされ、途上国での普及が滞る原因とされている。本研究は、ベースリスクを改善するため、深層学習や衛星データを用いたトウモロコシ単収推定モデルを構築し、農業保険に適用することで、新しい単収推定保険を提案した。

本研究の対象は、アメリカのトウモロコシとした。アメリカは世界でも有数のトウモロコシ生産国であり、食料安全保障上、重要な作物であるといえる。2008年から2013年の1kmメッシュ気象データ Daymet と MODIS から推定した植生指数 EVI を入力データとし、アメリカ農務省が公開する郡レベルのトウモロコシ単収を推定するモデルを深層学習で構築した。単収推定モデルの精度を評価するために、cross validation の手法を適用した。結果、全米のトウモロコシ単収を単一の推定モデルで、 $R^2=0.780$ という高い精度で推定することが可能となった。既往研究は、州単位など非常に限定的な範囲を推定しているため、本研究の有用性は高いといえる。さらに、サポートベクターマシンやオートエンコーダなど複数の機械学習アルゴリズムでも単収推定を行い、推定精度の比較を行うことで、深層学習の次元圧縮能力の有効性を確認した。

深層学習による単収推定モデルの性能を評価するため、「適用範囲の限定」、「汎化性の評価」、「衛星データの有効性」の3つの観点でそれぞれ実験を行った。適用範囲の限定では、推定対

象範囲を全米からトウモロコシ主要産地である Heartland 地方に絞った。結果、 $R^2=0.89$ となり、推定精度の大幅な向上が確認された。トウモロコシは、アメリカの各地で栽培されているため、品種や栽培環境（施肥や灌漑など）が地域によって大きく異なる可能性がある。本研究の単収推定モデルでは、品種や栽培環境に関する特徴量が与えられていないため、対象地域を限定することで、推定精度が向上したと考えられる。汎化性の評価では、leave-one-out cross validation (LOOCV) による時間軸方向の汎化性を評価した。2008 年から 2013 年までの 6 年間のデータのうち、各年を学習用データセットから取り除き、5 年分のデータで学習させた単収推定モデルを、検証年のデータで評価した。結果、有意な推定精度は得られなかった。衛星データの有効性では、入力データを Daymet のみの場合と、MODIS EVI のみの場合で単収推定モデルを学習し、推定精度を確認した。結果、Daymet のみで単収推定した場合、Daymet と EVI で学習した場合より、推定精度が若干低下した。EVI のみでは、有意な推定精度が得られなかった。よって、深層学習で単収推定モデルを構築する場合、気象データや衛星の植生指数を組み合わせた入力データセットが有効であると考えられる。

上記で構築した単収推定モデルは、郡レベルのものとなっている。トウモロコシ主要産地の郡は、およそ 35km となっており、郡内でもトウモロコシ生産が不均一であることから、ベースリスクが潜在することが懸念される。そこで、本研究では、郡レベルのトウモロコシ単収を 1km へ推定するダウンスケーリングを行った。深層学習で構築したトウモロコシ単収推定モデルに、1km メッシュの入力データを入力し、郡レベルの単収から 1km メッシュの単収データにダウンスケーリングを行った。ダウンスケーリング単収は、収穫面積が小さい地域において過少推定の傾向があった。しかし、ダウンスケーリング単収と郡レベルの単収をそれぞれマッピングし、比較したところ、お互いの分布が非常に似ており、ダウンスケーリング単収はより詳細な単収分布を示していることがわかった。

ダウンスケーリングしたトウモロコシ単収を活用し、新しい農業保険である単収推定保険を提案した。保険設計には、アメリカ農地の大部分で適用されている収入保険を参考にした。単収推定保険が農家の収入の保証状況を確認するため、トウモロコシ生産による営業利益（売り上げからコストを差し引いた額）に保険金を合算することで、赤字であった営業利益が黒字に転換できたかを確認した。2012 年は歴史的に深刻な干ばつが見舞われた年で、広い地域で大きな損害を被ったが、単収推定保険を適用することで、天候不順による損害をカバーできたことが確認できた。一方で、メッシュ気象データの最大気温を用いて、天候インデックス保険を設計し、単収推定保険と同様に営業利益の保証状況を確認した。天候インデックス保険でも、干ばつ年において多額の保険金支払いが発生し、農家の収入の保証が達成されたが、損失額に応じた金額の支払いではなかった。営業利益が黒字であった地域に対して、より多額の保険金支払いが発生したため、利益格差の拡大が生じたことから、ベースリスクが存在しているといえる。単収推定保険では、農家の営業利益に応じて補償が成されているため、損失が大きい地域に対して、多額な保険金支払いが実行された。よって、単収推定保険は、天候インデックス保険よりもベースリスクが低減された保険金支払いが可能であることが確認された。さらに、アメリカでは、その他の天候リスクや価格リスクによって損失を被るため、干ばつが発生しな

かった年においても営業利益の黒字を確保できない地域は存在した。単収推定保険では、天候インデックス保険が保険金支払いを行わなかった地域や年に対して保険金支払いを行い、全ての損失に対して補償が可能となった。

農業保険は、途上国への導入に向けて数多くのパイロットプロジェクトが実施されている。今後は、気候災害による減収の損失を補填するだけでなく、価格リスクなどあらゆるリスクを補填する農業保険商品のニーズが強まると予想されている。単収推定保険は、作物単収を直接的に推定することによって、収入保険など高度な保険金支払いの仕組みを設計することが可能となる。よって、天候災害や価格リスクなど、より多くのリスクへの対処に期待でき、幅広いニーズを満たすこととなる。また、衛星データや深層学習などのデータマイニング技術を適用することで、天候インデックス保険と変わらない低コストの保険運用が実現でき、モラルハザードや逆選択などのリスクを縮小することができる。今後は、打ち上げが計画されている将来の衛星の観測データを活用し、気象観測ステーションが十分に配備されていない地域において、本手法を導入する必要がある。また、単収推定の高精度化や汎化性向上を達成するため、長期間データの利用、さらに多くの特徴量入力やニューラルネットワーク構造の改善が課題となる。

目次

第1章	はじめに	1
1.1	本研究の背景	1
1.1.1	世界の食料安全保障問題	1
1.1.2	気候変動による穀物生産への影響	2
1.2	農業保険による減収リスクの低減	4
1.2.1	農業保険の現状	4
1.2.2	農業保険の種類	5
1.2.3	農業保険の課題	5
1.2.4	日本での農業保険の取り組み	8
1.2.5	アメリカでの農業保険の取り組み	9
1.2.6	衛星リモートセンシングを活用したインデックス保険の開発	10
1.3	衛星リモートセンシングを活用した穀物モニタリング	11
1.3.1	衛星リモートセンシングを利用した単収推定	11
1.3.2	作物生長モデルのデータ同化手法による単収推定	11
1.3.3	機械学習による穀物単収推定	12
1.3.4	衛星リモートセンシングを用いた栽培作物の分類	12
1.4	本研究が提案する農業保険	13
1.4.1	衛星データと機械学習を用いた単収推定手法	14
1.4.2	単収推定のダウンスケーリング	14
1.4.3	単収推定モデルの農業保険への適用	14
1.4.4	本研究の対象	14
1.5	本研究の独自性	15
1.6	本研究の構成	15
第2章	気象データと単収の相関分析	18
2.1	分析の全体の流れ	18
2.2	分析に利用したデータ	19
2.2.1	アメリカ農務省の作物統計データ	19
2.2.2	長期再解析データ ERA-Interim	22
2.2.3	高分解能全球気象データ CRU	22
2.3	分析のためのデータ処理	24

2.3.1	作況指数の算出	24
2.3.2	面責按分による作況指数のラスターデータ化	24
2.3.3	暖かさ指数と露点差の算出	25
2.3.4	気象データの標準化	26
2.4	作況指数による作柄の評価	27
2.4.1	作況指数と実際に報告された単収実績の関連性	27
2.4.2	作況指数のラスターデータによる地域的な作柄の把握	27
2.5	ERA-Interim を用いた州レベルの相関分析	32
2.6	CRU を用いた郡レベルの相関分析	34
2.7	考察	41
2.7.1	作況指数による作柄の評価	41
2.7.2	複数気象データセットを用いた分析の考察	41
2.7.3	気象データセットを用いた天候インデックス保険に関する考察	41
第 3 章	天候インデックス保険の開発	43
3.1	既存の天候インデックス保険の開発方法	43
3.2	本研究の天候インデックス保険	45
3.2.1	本研究で設計した天候インデックス	45
3.2.2	天候インデックス保険の評価	45
3.2.3	2008 年から 2013 年の天候インデックス保険の結果	46
3.3	天候インデックス保険の考察	64
第 4 章	衛星データと深層学習による単収推定モデルの開発	65
4.1	既存手法と本研究による作物単収推定	65
4.1.1	作物生長モデルによる単収推定	65
4.1.2	衛星データと機械学習による単収推定	67
4.1.3	作物生長モデルと機械学習による手法の比較	68
4.2	機械学習によるトウモロコシ単収推定	69
4.2.1	本研究で利用した機械学習アルゴリズム	70
4.2.2	単収推定のための学習方法	74
4.3	単収推定で利用したデータ	74
4.3.1	北米高解像度気象データ Daymet	74
4.3.2	衛星植生指数 EVI	74
4.3.3	植生指数 EVI のノイズ除去	75
4.3.4	入力データの正規化	78
4.3.5	土地被覆データによる入力データのマスクング	78
4.3.6	収量推定精度の評価	79
4.4	単収推定の結果	80

4.5	推定結果の考察	82
第 5 章	深層学習による単収推定モデルの性能評価について	83
5.1	第 5 章の目的	83
5.2	推定精度向上のための対象範囲の限定	85
5.2.1	Heartland 地方のみのデータ利用	85
5.2.2	Heartland 地方のトウモロコシ単収の推定結果	86
5.3	深層学習の汎化性の評価	88
5.3.1	既往研究の汎化性評価について	88
5.3.2	本研究の汎化性評価	88
5.3.3	深層学習による単収推定モデルの汎化性評価の結果	89
5.4	EVI が深層学習の推定精度に与える影響の評価	90
5.4.1	EVI の評価実験の方法	90
5.4.2	EVI 評価実験の結果	90
5.5	考察	91
5.5.1	対象範囲限定による精度向上の考察	91
5.5.2	汎化性に関する考察	91
5.5.3	EVI が単収推定モデルの精度に与える影響の考察	91
第 6 章	トウモロコシ単収のダウンスケーリング手法の開発	92
6.1	単収ダウンスケーリングの重要性	92
6.2	既存のダウンスケーリング	92
6.3	本研究のダウンスケーリングの手法	93
6.4	ダウンスケーリング結果と検証	93
6.4.1	USDA の郡レベルの収穫面積と CDL の比較	93
6.4.2	ダウンスケーリングの結果	93
6.5	単収ダウンスケーリングの考察	101
第 7 章	単収推定モデルによる単収推定保険の開発	102
7.1	本研究で適用する単収推定保険の考察	102
7.1.1	天候インデックス保険の考察	102
7.1.2	単収推定保険の考察	103
7.1.3	本研究が適用する農業保険	103
7.2	本研究が開発する農業保険	104
7.2.1	収入保証保険	104
7.2.2	本研究の収入保証保険の評価	105
7.2.3	保険計算に用いるデータ	105
7.2.4	保険計算の対象	106

7.3	収入保険の計算結果	107
7.3.1	2008年の結果	107
7.3.2	2009年の結果	107
7.3.3	2010年の結果	107
7.3.4	2011年の結果	107
7.3.5	2012年の結果	108
7.3.6	2013年の結果	108
7.4	本研究の農業保険の考察	127
7.4.1	ベースリスクの改善について	127
7.4.2	従来保険の課題解決について	127
7.4.3	本研究の新規性	127
第8章	天候インデックス保険と単収推定保険の比較	129
8.1	カバー率の計算	129
8.2	天候インデックス保険と単収推定保険のカバー率の結果	129
8.3	考察	131
第9章	途上国及び新興国への農業保険導入のための考察	132
9.1	発展途上国の農業に深刻な被害を与える自然災害の発生	132
9.2	各国の農業保険の導入状況と市場の特徴	135
9.2.1	農業保険の導入状況	135
9.2.2	農業保険の組織形態	135
9.2.3	アメリカの農業保険制度	136
9.2.4	日本の農業共済保険制度	136
9.2.5	中国の農業保険	137
9.2.6	アジアやアフリカの農業保険	137
9.3	拡大する保険責任の受け入れ先	144
9.3.1	多国間災害保険プール	144
9.3.2	保険リンク証券	144
9.4	データの取得可能性	146
9.4.1	衛星の運用状況と打ち上げ計画	146
9.4.2	気象データ	149
9.4.3	収量データ	151
9.5	今後途上国で導入される農業保険	152
9.5.1	今後の農業保険市場の見通し	152
9.5.2	今後開発される新しい農業保険	152
9.5.3	大規模災害の対策となる農業保険	153

第 10 章 まとめと今後の展望	154
10.1 各章のまとめ	154
10.1.1 第 8 章：天候インデックス保険と単収推定保険の比較	157
10.2 今後の展望	159
付 録 A Heartland 地方のトウモロコシ価格及び栽培に要するコスト	161
付 録 B 機械学習による単収推定モデルの汎化性評価	162
参考文献	165
本研究に関する研究発表の一覧	170
謝辞	171

目 次

1.1	2050年までの世界人口 (United Nation, 2015)	3
1.2	世界の穀物の収穫面積と単位面積当たり収量	3
1.3	本研究で取り組んだ手法の流れ	15
2.1	単収と再解析データの時空間相関分析の流れ	19
2.2	アメリカの単収及び収穫面積	21
2.3	2008年アメリカの郡レベルのトウモロコシ単収	21
2.4	2008年アメリカの郡レベルのトウモロコシ収穫量	22
2.5	面積按分の例	25
2.6	アメリカの主要穀物の作況指数	29
2.7	トウモロコシ作況指数をクラスタリングした分布図	30
2.8	1960年から2013年のトウモロコシ作況指数のヒストグラム	30
2.9	凶作シーズンだったトウモロコシ作況指数	31
2.10	トウモロコシ作況指数と月積算の ERA-Interim との相関分析	33
2.11	CRU と作況指数の相関分析 (1月)	35
2.12	CRU と作況指数の相関分析 (2月)	35
2.13	CRU と作況指数の相関分析 (3月)	36
2.14	CRU と作況指数の相関分析 (4月)	36
2.15	CRU と作況指数の相関分析 (5月)	37
2.16	CRU と作況指数の相関分析 (6月)	37
2.17	CRU と作況指数の相関分析 (7月)	38
2.18	CRU と作況指数の相関分析 (8月)	38
2.19	CRU と作況指数の相関分析 (9月)	39
2.20	CRU と作況指数の相関分析 (10月)	39
2.21	CRU と作況指数の相関分析 (11月)	40
2.22	CRU と作況指数の相関分析 (12月)	40
3.1	降水量をインデックスとした天候インデックス保険	44
3.2	標準化した気温をインデックスとした天候インデックス保険	46
3.3	郡レベルの営業利益 (2008年)	47
3.4	郡レベルの営業利益のヒストグラム (2008年)	47

3.5	郡レベルの営業利益（2009年）	49
3.6	郡レベルの営業利益のヒストグラム（2009年）	49
3.7	郡レベルの営業利益（2010年）	51
3.8	郡レベルの営業利益のヒストグラム（2010年）	51
3.9	郡レベルの天候インデックスの保険金（2010年）	52
3.10	天候インデックス保険の保険金のヒストグラム（2010年）	52
3.11	郡レベルの利益（2010年）	53
3.12	郡レベルの利益のヒストグラム（2010年）	53
3.13	郡レベルの営業利益（2011年）	55
3.14	郡レベルの営業利益のヒストグラム（2011年）	55
3.15	郡レベルの天候インデックスの保険金（2011年）	56
3.16	天候インデックス保険の保険金のヒストグラム（2011年）	56
3.17	郡レベルの利益（2011年）	57
3.18	郡レベルの利益のヒストグラム（2011年）	57
3.19	郡レベルの営業利益（2012年）	59
3.20	郡レベルの営業利益のヒストグラム（2012年）	59
3.21	郡レベルの天候インデックスの保険金（2012年）	60
3.22	天候インデックス保険の保険金のヒストグラム（2012年）	60
3.23	郡レベルの利益（2012年）	61
3.24	郡レベルの利益のヒストグラム（2012年）	61
3.25	郡レベルの営業利益（2013年）	63
3.26	郡レベルの営業利益のヒストグラム（2013年）	63
4.1	衛星データによる作物生長モデルのデータ同化手法	66
4.2	GHCNDの気象観測ステーションの分布密度	69
4.3	本研究の機械学習のデータ処理の流れ	70
4.4	本研究のDNNの概念図	72
4.5	ニューロンのモデル	72
4.6	Autoencoderの概念図	73
4.7	MODIS EVIとWavelet変換でスムージングしたEVI	77
4.8	Wavelet変換でスムージングした北米のEVI（2008年7月18日）	77
4.9	2008年のCDL	79
4.10	SVMによるトウモロコシ単収推定	81
4.11	DNNによるトウモロコシ単収推定	81
4.12	Autoencoderによるトウモロコシ単収推定	82
5.1	Farm resource region	85

5.2	Illinois 州 Kankakee 郡周辺の耕作地帯（左） Kansas 州 Stafford 郡周辺の耕作地帯（中） Washington 州 Benton 郡周辺の耕作地帯（右）	86
5.3	Heartland 地方のみのデータで学習した DNN によるトウモロコシ単収の推定結果	87
5.4	LOOCV によるトウモロコシ単収推定の結果	89
6.1	CDL と USDSA のトウモロコシ収穫面積の比較評価の流れ	94
6.2	CDL のトウモロコシ畑面積と USDA の収穫面積	94
6.3	トウモロコシ単収のダウンスケーリング結果（2008 年）	95
6.4	USDA のトウモロコシ単収（2008 年）	95
6.5	トウモロコシ単収のダウンスケーリング結果（2012 年）	96
6.6	USDA のトウモロコシ単収（2012 年）	96
6.7	郡ごとに再集計したダウンスケーリング単収と USDA の単収（2008 年）	97
6.8	郡ごとに再集計したダウンスケーリング収穫量と USDA の収穫量（2008 年）	97
6.9	郡ごとに再集計したダウンスケーリング単収と USDA の単収（2012 年）	98
6.10	郡ごとに再集計したダウンスケーリング収穫量と USDA の収穫量（2012 年）	98
6.11	ダウンスケーリングした単収と USDA の単収のヒストグラム（2008 年）	99
6.12	ダウンスケーリングした単収と USDA の単収のヒストグラム（2012 年）	100
7.1	トウモロコシ栽培による営業利益推計（2008 年）	109
7.2	トウモロコシ栽培による営業利益推計のヒストグラム（2008 年）	109
7.3	本研究の収入保険による補償金推計（2008 年）	110
7.4	本研究の収入保険による補償金推計のヒストグラム（2008 年）	110
7.5	トウモロコシ栽培による利益推計（2008 年）	111
7.6	トウモロコシ栽培による利益推計のヒストグラム（2008 年）	111
7.7	トウモロコシ栽培による営業利益推計（2009 年）	112
7.8	トウモロコシ栽培による営業利益推計のヒストグラム（2009 年）	112
7.9	本研究の収入保険による補償金推計（2009 年）	113
7.10	本研究の収入保険による補償金推計のヒストグラム（2009 年）	113
7.11	トウモロコシ栽培による利益推計（2009 年）	114
7.12	トウモロコシ栽培による利益推計のヒストグラム（2009 年）	114
7.13	トウモロコシ栽培による営業利益推計（2010 年）	115
7.14	トウモロコシ栽培による営業利益推計のヒストグラム（2010 年）	115
7.15	本研究の収入保険による補償金推計（2010 年）	116
7.16	本研究の収入保険による補償金推計のヒストグラム（2010 年）	116
7.17	トウモロコシ栽培による利益推計（2010 年）	117
7.18	トウモロコシ栽培による利益推計のヒストグラム（2010 年）	117
7.19	トウモロコシ栽培による営業利益推計（2011 年）	118
7.20	トウモロコシ栽培による営業利益推計のヒストグラム（2011 年）	118

7.21	本研究の収入保険による補償金推計（2011年）	119
7.22	本研究の収入保険による補償金推計のヒストグラム（2011年）	119
7.23	トウモロコシ栽培による利益推計（2011年）	120
7.24	トウモロコシ栽培による利益推計のヒストグラム（2011年）	120
7.25	トウモロコシ栽培による営業利益推計（2012年）	121
7.26	トウモロコシ栽培による営業利益推計のヒストグラム（2012年）	121
7.27	本研究の収入保険による補償金推計（2012年）	122
7.28	本研究の収入保険による補償金推計のヒストグラム（2012年）	122
7.29	トウモロコシ栽培による利益推計（2012年）	123
7.30	トウモロコシ栽培による利益推計のヒストグラム（2012年）	123
7.31	トウモロコシ栽培による営業利益推計（2013年）	124
7.32	トウモロコシ栽培による営業利益推計のヒストグラム（2013年）	124
7.33	本研究の収入保険による補償金推計（2013年）	125
7.34	本研究の収入保険による補償金推計のヒストグラム（2013年）	125
7.35	トウモロコシ栽培による利益推計（2013年）	126
7.36	トウモロコシ栽培による利益推計のヒストグラム（2013年）	126
9.1	自然災害の発生件数と被害額	133
9.2	地域別の洪水発生割合	134
9.3	地域別の暴風雨発生割合	134
9.4	地域別の干ばつ発生割合	134
9.5	地域別の地震発生割合	134
9.6	地域別の熱波・寒波発生割合	134
9.7	農業保険市場のタイプと特徴	140
9.8	アメリカの農業保険制度	142
9.9	アメリカの作物保険のコスト	143
9.10	日本の農業共済制度	143
9.11	Planet の超小型衛星 Dove	149
A.1	Heartland 地方におけるトウモロコシの価格および単収	161
A.2	Heartland 地方におけるトウモロコシ栽培に要するコスト	161
B.1	2008 年を学習データセットから外した単収推定結果	162
B.2	2009 年を学習データセットから外した単収推定結果	163
B.3	2010 年を学習データセットから外した単収推定結果	163
B.4	2012 年を学習データセットから外した単収推定結果	164
B.5	2013 年を学習データセットから外した単収推定結果	164

表 目 次

1.1	各種農業保険の特徴	6
1.2	インデックス型保険のベシスリスク	13
2.1	アメリカのコーンベルトで発生した大規模な天候不順	29
4.1	推定手法の比較	69
4.2	Estimation results with several models	80
7.1	保険計算で扱うパラメータ	105
7.2	栽培コストの内訳	106
8.1	天候インデックス保険と単収推定保険のカバー率	130
9.1	アジア諸国の農業保険の導入状況	139
9.2	アジア諸国の農業保険市場のタイプ	141
9.3	保険リンク証券のトリガーの種類	145

第1章 はじめに

1.1 本研究の背景

1.1.1 世界の食料安全保障問題

2050年の世界人口は、96億人に達するといわれており、2015年時点の約70億人から、およそ28%も増加すると予測されている（図1.1）。この増加のほとんどが開発途上国で起こるもので、世界人口の4割以上をインドや中国が占める。途上国のうち、サハラ以南アフリカの人口の増加が114%で最も早く、東および東南アジアが13%で最も遅い。さらに都市化が引き続き加速すると予測されている。都市部が世界人口に占める割合が現在の49%から、2050年には70%となり、農村人口は減少する見込みとなっている。同時に2050年の一人当たり所得は現在の水準の数倍になる見込みで、所得における相対的な不平等は、かなり減少するとみられている。

人口増加に伴い急増する食料需要を満たすためには、2005年時点の食料生産力を2050年で1.7倍に引き上げる必要があるといわれている（FAO, 2009）。アジアの国々では中間富裕層の人口が主に増加するため、食肉需要が急増し、畜産用の飼料用穀物の需要が高まることが予測される。FAO（2006）では、2050年の世界の穀物需要は、2001年時点の1.6倍まで増大すると予想されており、飼料穀物や油糧種子の生産力を引き上げる必要があると懸念している。

FAOの統計データによると、世界の穀物栽培面積は1960年代からほぼ横ばいで推移している（図1.2）。単位面積当たり収量（単収）は、1960年代から1990年まで線形に上昇しており、1990年代以降になると飛躍的に伸びている。これは、施肥技術、品種改良や遺伝子組換え作物による効果が大きいといわれている（Conradt *et al.*, 2014）。しかし、OECD & FAO（2015）では、今後、単収の伸び率は鈍化すると予想しており、近年、主要穀物の主産地での干ばつなどの天候不順の影響も加わり、生産量は伸び悩むとされている。

先にも述べたように、農家の人口は世界的に減少する傾向にあり、なお、近年、頻発している天候不順の影響で、世界各地の穀物生産量は不安定にある。今後、食料生産力を安定的に高めるためには、従来の資源投入による生産量増加ではなく、資源を有効活用した効率化が必要となる。また、天候不順のリスクに脆弱な農業・農家をサポートする経済的な仕組みも整え、安定的に作物生産を可能にする体制を気付くことが重要と考えられる。

1.1.2 気候変動による穀物生産への影響

FAOが2003年から2013年の期間を世界規模の気候関連の自然災害を分析した。FAO (2015b)によると、災害により発生した惨事の件数は年間平均で1980年代からほぼ倍増した。経済への被害合計額は1.5兆ドルに及ぶと推定している。開発途上国で、農業が産業に占める割合は高く、経済へのマイナスの影響も高い。特に家畜と作物生産は、気候災害に対して脆弱とされている。

サブサハラアフリカは、農業が平均してGDPの四分の一を占め、大規模な干ばつが起きた後の農作物及びの家畜の損失は大きい。1991年から2013年で300億ドル以上にものぼるといわれている。

アジアの多くの国では、洪水や暴風の影響に脆弱となっている。2010年や2015年のパキスタンの洪水では、コットン、米、小麦に多大な影響を与え、輸入へ大きな影響を与えた。

世界有数の穀倉地帯であるアメリカでも、2012年に50年に一度といわれるほどの大規模な干ばつが発生した。アメリカ中西部に位置するコーンベルトでは、トウモロコシや大豆の生産に深刻な被害を与えた。これが原因で、世界の穀物価格が50%以上も急騰し、世界中で食料危機が懸念された。2010年、ロシアの穀倉地帯でも深刻な干ばつが発生し、小麦などの生産量が激減した。ロシア政府より、穀物の輸出禁止措置がなされた。それにつづき、ウクライナやカザフスタンでも穀物の輸出禁止が行われた。穀物備蓄を行っている国々はともかく、アフリカなどの国々には、飢餓問題へと直結し、暴動になりかねないと国連では懸念された。

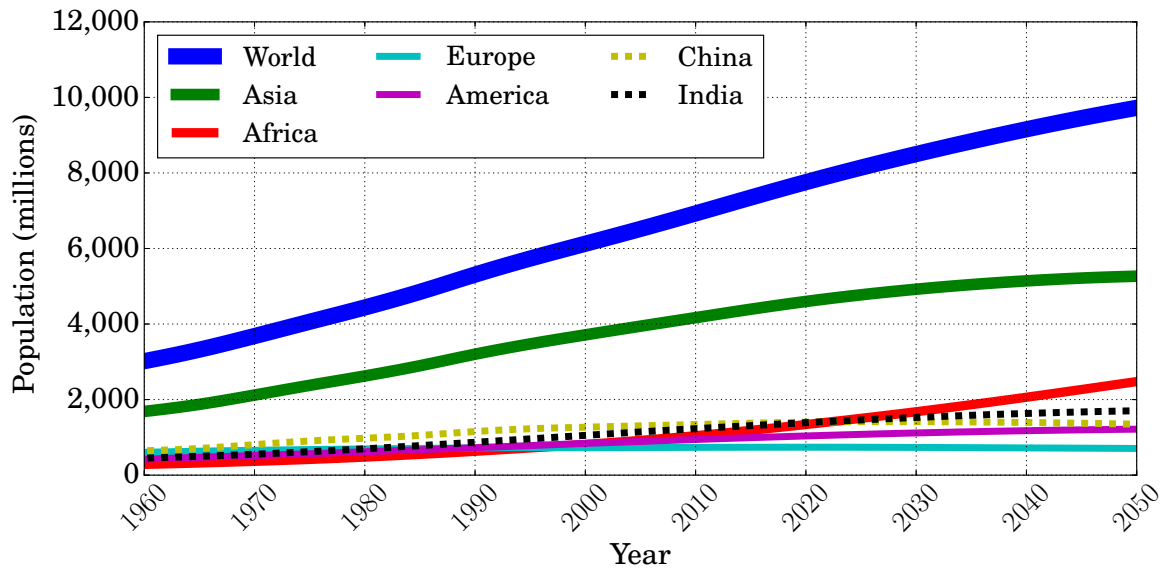


図 1.1 2050 年までの世界人口 (United Nation, 2015)

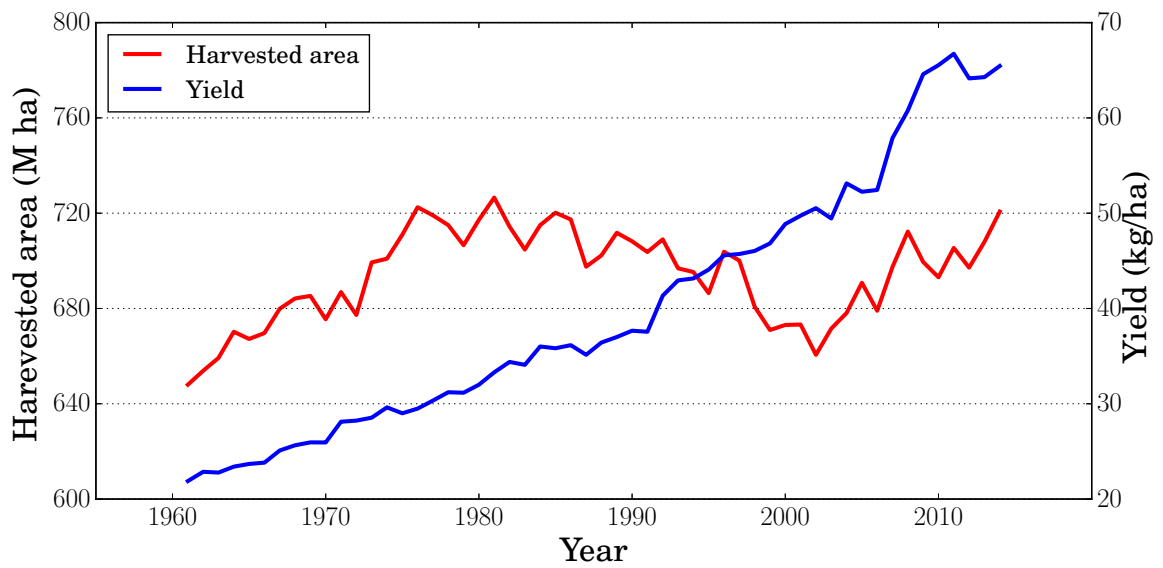


図 1.2 世界の穀物の収穫面積と単位面積当たり収量

1.2 農業保険による減収リスクの低減

1.1.1では、人口増加によって食料需給が逼迫すると懸念され、食糧生産の効率化は食料安全保障において重要な課題として述べた。しかし、食糧生産の基盤となる農業は、自然災害によって大きな損害を受けている。特に天候不順のリスクに対して脆弱となっている。まずは、天候リスクが寄与する農業生産の不安定化を軽減することが、最優先事項の一つであると考えられる。この重要事項の解決方法として、本研究では、農業保険を着目する。まず、以下に農業保険の現状、種類や課題について述べ、本研究が提案する農業保険について焦点を当てる。

1.2.1 農業保険の現状

農業保険とは、農業、畜産業、漁業、林業に関連する保険であり、外的要因（天候や災害など）によって引き起こされた損害を補填するための保険である。農業は、天候による影響を特に受けるため、食料安全保障上の観点に加えて開発途上国に対する気候変動適応作対応策として、注目されている。2011年時点の農業保険の世界市場は、保険料ベースで243億ドルとなっており、最大国は米国（114億ドル）、2位は中国（25億ドル）、3位はカナダ（22億ドル）となっている。米国で農業保険の全市場のおよそ半分を占めている。中国は、市場規模がアジアで最大の国であり、2008年頃に世界2位へと浮上した。農業保険の世界市場の年平均成長率は、20%となっており、現在もアジアや中南米などの新興国を中心に成長する見込みである。

アジア諸国では、農業の生産額が全産業に占める割合が欧米と比較して非常に高いため、自然災害が農業に与える経済的インパクトは、欧米の25倍といわれている。農作物が収穫前に自然災害の被害を受けた場合、農家は十分な収益を得られず、負債を負うことになる。そして、次の作付けに向けて、種子や肥料などを購入する必要があるが、このような場合、銀行からの借入金額は減少する。投入資材が減少するため、作付け面積の縮小、品質の劣る資源（肥料や農薬など）を投入するため、自然災害が発生しない場合でも収穫量が減少する可能性が高い。この様に、一度の大規模な自然災害を発端とし、貧困へのスパイラルに陥る危険がある。農業保険は、このような自然災害によって引き起こされる損害リスクを補填する金融商品である。アジアでは小規模農家が多く、アジアの平均農地面積は、世界の5分の1となっている。農業保険をアジアの多くの農家に適用し、天候や自然災害による被害損失をカバーすることが可能になれば、貧困対策への貢献に期待できる。よって、農業保険がアジアにもたらす経済効果は高く、食料安全保障上、非常に重要であると考えられる。

農業保険の普及率は、米国では9割を超えるが、新興国・発展途上国ではほとんど普及していないのが現状である。その大きな理由として、農民が保険に対する十分な知識を持っていないという事が挙げられる。多くの農民は、リスク移転という保険の主目的を理解していないため、正当な手段で保険を購入しないケースが多い。さらに農業保険は、自然災害によって被る損害リスクを補填するためのものであるため、支払い頻度は小さい。農民は、収穫量の減少について強く認識するが、過去の自然災害による被害リスクは過小評価する傾向にある。自然災害

に対するリスク認識が低いいため、農業保険を購入するインセンティブは農民にとって小さいと考えられる。また、農業保険を提供する場合、農作物の被害状況を観測するためのインフラ整備や仕組みづくりが必要となる。途上国では、コスト高や農業保険を販売してリスクを補填する仕組みが整っていないため、導入が困難とされている。よって、途上国では、政府や国際機関による災害支援、海外企業とのパイロットプロジェクトとして農業保険が販売されている。

1.2.2 農業保険の種類

農業保険は、主に二つに分類できる。従来型とインデックス型である。従来型は、損害補償型保険と作物収入保険（crop revenue insurance）の二つに分けられる。インデックス型は、面積当たり収量インデックス保険（area yield index insurance）と天候インデックス保険（weather index insurance）の二つに分けられる。よって、農業保険は、主に5つの種類が存在する。

損害補償型保険は、補償対象地に調査員を派遣し、実際の損害額を見積もり、被保険者に補償金を支払う保険である。列举危険農作物保険（NPCI：Named Peril Crop Insurance）と複合危険農作物保険（MPCI：Multi Peril Crop Insurance）の二つが主に存在する。NPCIは、世界で最も広く利用されている農業保険である。雹、火事、暴風、霜などの内、保険約款に規定されたリスクのみ収穫量の減少を補償する保険である。MPCIは、NPCIでは補償されない干ばつや洪水など、広域に影響を及ぼすリスクに対し、収穫量の補償を行う。

作物収入保険は、収穫量の減少や農作物価格の下落に伴う農家の収入減少を補償する保険である。この保険は、他の保険と異なり、市場リスクを直接的にカバーしており、農家によるニーズがより高まっていると言われている。

インデックス型保険は、定量的に観測可能なデータ（降水量、気温や地域の平均単位面積当たり収量）をインデックスとし、予め設定した閾値を下回る、もしくは上回れば、それに応じて自動的に補償金が支払われる保険である。面積当たり収量インデックス保険は、広域範囲（郡など）の平均収量をインデックスとし、閾値が下回った場合に契約農家に対し補償金を支払う保険である。天候インデックス保険は、降水量や気温など作物の収量と強い相関関係にある観測データをインデックス化し、作物生長を阻害する条件になった場合、自動的にトリガーとなって補償金が支払われる保険である。

1.2.3 農業保険の課題

1.2.2で述べた農業保険には、それぞれ長所と欠点を有する。本研究では、6つの観点から農業保険を評価し、表1.1にとりまとめたものを示す。

従来型の保険は、情報の非対称性に起因する逆選択とモラルハザードが大きな問題となっている。情報の非対称性とは、保険提供者と被保険者が有する情報の格差で発生する。特に被保険者が保険会社より正確な情報を持っていた場合のことを指す。気象データや地域平均の収穫

表 1.1 各種農業保険の特徴

		逆選択の抑止	モラルハザードの抑制	補償金支払いの即時性	保険運用に要するコスト	ベシスリスクの課題	価格リスクへの対応
従来型	損害補償型	列挙危険農作物保険				✓	
		複合危険農作物保険				✓	
	作物収入保険					✓	✓
インデックス型	面積当たり収量インデックス保険	✓	✓				
	天候インデックス保険	✓	✓	✓	✓		

量をインデックスとする保険は、観測が困難な被保険者が有する特徴（栽培技術やリスクの受容性）に依存しないため、逆選択やモラルハザードが起これにくいと考えられている。

逆選択の抑止

逆選択とは、リスクが高い農家の方が保険に加入するインセンティブが高いため、高リスクの農家ばかりが加入してしまい、その結果、保険会社は保険料を引き上げざるを得なくなり、ますます低リスクの農家が淘汰され、最悪の場合は保険市場が成立しなくなってしまうという問題である。例えば、栽培技術（施肥、農薬投入、灌漑管理など）の経験的な差より、高い収量を得られる農家と低い収量しか得られない農家が存在する。低収量の農家は、農業保険への加入のインセンティブが強いため、逆選択が発生する。さらに、低収量の農家の方が、補償金支払いの頻度が高いため、保険会社の負担はより大きくなる危険性がある。

モラルハザードの抑制

モラルハザードは、被保険者が保険に加入し、収入が保証される安心によってリスクへの対処を怠り、リスクの高い行動を取ってしまうという問題である。農家は、農業保険に加入後、収入が保証されるため、肥料、水、農薬投与などの農作業を怠るといった行動がみられる。このリスクを判別するため、保険提供者が農家の行動をモニタリングすることになれば、高額な事業コストが必要となり、民間保険会社の参入は難しくなる。

補償金支払いの即時性

それぞれの農業保険は、被保険者に補償金が支払われるタイミングが異なる。従来型の保険と面積当たり収量インデックス保険は、契約農家の収穫状況を調査する必要がある。よって、農作物の収穫後に調査を行い、査定することで補償金が支払われる。補償金額の支払いは、収穫後2から3ヶ月後になる。一方、天候インデックス保険は、インデックスとなる気象データがある条件になった際に自動的に補償金が支払われるため、収穫期を待たなくても資金を調達することが可能である。補償金支払いの即時性に関して、天候インデックス保険が最も速く、農家にとって有効であるといえる。

保険運用に要するコスト

保険事業を行う際、様々なコストがかかる。特に損害額を見積もるために行う査定に要する人件費が大きくなる。調査査定を行う従来型の保険と面積当たり収量インデックス保険は、コストが最も大きな課題であるといわれている。天候インデックス保険は、査定を必要としないため、他の農業保険と比較してコストが低いと考えられている。

ベースリスクの課題

ベースリスクとは、補償金額と実際の損害額が乖離するリスクである。従来型の保険の場合、調査員を現場に派遣し、損害額を実際に見積もるため、補償金額は天候不順や自然災害で農家が受ける損失に則していると考えられる。天候インデックス保険では、気象観測ステーションのデータが補償金額決定のトリガーとなる。被補償農地が気象観測ステーションから非常に離れている場合、双方の気象条件が大きく異なる可能性があり、補償金の未払いもしくは過払いのリスクが大きくなる。天候インデックスは、ベースリスクこそが一番の課題であるといわれている。面積当たり収量インデックス保険においても、基準となる平均・期待収穫量の地域が広大であると、気象条件が大きくばらつき、地域内の収穫量の分散が大きくなり、ベースリスクも大きくなる。ベースリスクが大きくなると、補償金の支払いと天候不順や災害による収穫量減少の相関関係が弱くなり、被保険者にとって農業保険の有用性がなくなってしまう。ベースリスクの問題点より、途上国では、農家は農業保険を宝くじ感覚で購入するケースが多く存在し、本来の農業保険の目的を果たしていない。気象観測ステーションの設置数を増やすことで、ベースリスクの解消に期待できるが、数を増していけば設備投資にコストがかさみ、天候インデックス保険の利点が損なわれてしまう。

価格リスクへの対応

損害保障型やインデックス型保険は、作物の減収のリスクをカバーする保険となっているため、価格の変動によって農家が被る損失のリスクはカバーされていない。天候不順によって作

物の収量は減少することで、農家は損害の補填を必要とするが、豊作によって価格が下落し、損失を被る場合もある。作物収入保険は、このような価格リスクによる損失をカバーする保険であり、導入している国はアメリカやブラジルなど非常に少ない。アメリカの様に世界最大の穀倉地帯を有し、自由経済を採用している市場では、農作物の価格変動リスクは非常に高いため、価格リスクを軽減する保険商品のニーズが高かったことが考えられる。

農作物の価格は、作物の収穫具合はもちろん、原油価格や海外の作物事情などあらゆる情報の影響を受け、逐次的に変動する。よって、価格リスクを農業保険で補填する場合、作物収量と直接的に関係を持たない天候インデックスでは、価格リスクをカバーする農業保険の設計は困難となっている。

1.2.4 日本での農業保険の取り組み

日本には、農業共済制度というものがある。農家による掛金で共同準備財産をつくり、災害が発生した際に共済金を支払い、自然災害によって発生した収量減少などの被害の補填を行う。この制度は、1947年より発足し、自然災害によって被災した多くの農家と地域経済の安定化に貢献してきた。

農業共済制度の補償対象は、米、麦、畑作物、果樹、園芸施設、家畜などだが、水稻への加入戸数が最も多い。1995年の大冷害の年では、共済金の支払いは約4400億円となった。この時、東北地方の稲作作況指数は56（全国平均は74）となり、被害額は4690億円に達した。その他にも、やませや台風の影響で、水稻収量が例年の半分以下となる深刻な損害が発生した例もある。

水稻共済の損害査定は、農家から被害の深刻があった全圃場について、損害評価員（農家の代表）が目視などで収量把握を行う。さらにその一部の圃場を農業共済組合及び連合会がサンプル調査を行い、目視調査の結果を修正する手法が一般となっている。損害評価員は、農家から3人選ばれ1組で調査を行う。評価員は、農家であるため、自分の地域を調査することはできない仕組みとなっている。目視を中心に単収を推測することから、十分な経験と豊富な知識等が必要となる。しかし、農家数の減少や高齢化が進み、高い評価技術を有した損害評価員の確保が困難となっている。

自然災害が日本各地でも多発している状況下において、農家の経営安定に寄与する農業保険の仕組みはますます必要である。そのために近年、現行の損害評価方を代替する一つとして、衛星画像を取り入れた損害評価の活用が進められている。中分解能衛星画像（分解能1mほど）のスペクトル情報から算出する植生指数を説明変数とし、GIS圃場ポリゴンデータを組み合わせ、回帰分析手法による収量推計手法を農林水産省の事業として開発している。これまで、衛星の数が十分でなかったことから、観測適期に有効な衛星画像の取得が難しかった。今後は、大多数に打ち上げられる小型衛星の観測ネットワークを利用したモニタリングの開発が望まれる。

1.2.5 アメリカでの農業保険の取り組み

1938年、作物保険制度がアメリカで創設された。当初は、試験的に実施されたが、加入率の低さ、支払保険金が受取保険料を大きく上回るという問題を抱えていた。1980年の連邦作物保険法では、連邦政府が30%までの保険料補助を行うこと、対象となる作物や地域の大幅拡大、民間保険会社による保険販売などの制度改革を行い、保険加入者を促進させた。結果、面積加入率は、目標の50%まで到達しなかったものの、1980年の10%から91年度には32%まで上昇した。その理由として、災害があった年に特別措置によって予算の枠外で特別災害援助（Ad hoc Disaster Assistance）が実施されていたことが挙げられていた。農家は、自ら保険料を負担し、作物保険に加入せずとも、この特別災害援助によって自己負担なしで一定の支払を受ける事ができたので、保険加入のインセンティブが低かった。しかし、特別災害援助は、実施される条件、支払程度などが政治的な要因で不確定であり、被災農家への対策として、十分なものではなかった。

この様なながれで、1994年改革法によって、作物保険と特別災害援助を一本化する改正がなされた。そこで、わずかな手数料で加入できる、大災害作物保険プログラム（CAT: Catastrophic Crop Insurance Program）が導入された。CATの保証を超える損害をカバーしたい農家には、既存の複合危険作物保険プログラム（MPCI）を追加保証し、従来より高い保険料補助の下で提供した。アメリカでは、CATとMPCIの2段階で自然災害の損害を保証する仕組みとなっている。CATやMPCI以外に、郡の基準単収が下回る時に保証されるGRP（Group Risk Plan）も1993年から実施されている。

1994年の改正後、収入保険制度が創設されることになった。1996年から、連邦作物保険公社（FCIC: Federal Crop Insurance Corporation）がIP（Income Protection）を開発し、収入保険のパイロットプログラムとして実施された。また、民間保険会社によって開発されたCRC（Crop Revenue Coverage）が開発された。さらに1997年に農民連盟や民間保険会社、大学を中心にRA（Revenue Assurance）が開発された。農作物が豊作の場合、収穫量は例年よりも多くなり、市場で取引される価格が下がり、結果として豊作貧乏に陥る可能性がある。収入保険では、災害などによる損害と市場価格による減収を保証する保険である。

3つの収入保険は、保証金額の算定などが異なるが、共通点として、作物の保証価格に先物市場の情報を取り入れている。先物価格を保証価格に用いることで、市場の需給動向に即した保証水準が提供される。よって、保証価格の値段で農家が栽培作物を選択するという逆選択が起りにくいというメリットが考えられている。また、先物価格は、農作物の市場価格を用いるより、保険金の計算の額を早い時期に確定し、スムーズな支払が実行可能になる。

収入保険の導入で挙げられる問題点は、「適正な保険料率の算定」と「農業収入の的確な補足」が指摘されている。保険は、保険収支が均衡するように設計しなくては、持続性が得られない。そのためには、農家の農業収支を的確に把握する必要がある。農家が抱えるリスクは、天候や災害による自然リスクと市場価格のリスクなどが挙げられる。市場価格については、各国の農業政策に大きく関わるため、その国に合った保険制度を適用する必要がある。

1.2.6 衛星リモートセンシングを活用したインデックス保険の開発

衛星リモートセンシングは、地上の査定調査を代替する手段として大きく注目されている。日本の損害保険会社である損保ジャパンと一般財団法人リモート・センシング技術センター（RESTEC: Remote Sensing Technology Center for Japan）は、衛星データから作成される衛星全球こうマップ（GSMap）を活用した天候インデックス保険をミャンマーに適用した。衛星データから推定された雨量を活用した天候インデックス保険の開発は、日本初となった。

その他、衛星画像のスペクトル情報から算出する正規化植生指数（NDVI: Normalized Difference Vegetation Index）を用いたインデックス保険の提案がされている。しかし、NDVIは被雲時に値が大幅に下がり、地表面の作物を正確に定常的に観測することが困難である。インデックス型保険に用いるデータは、信頼性の高いデータでなければならない。また、NDVIの動向が作物収量と必ずしも関係しているとはいえない。衛星データの保険への適用は、安定的に情報を取得し、収量を高い精度で推定する手法を開発する必要がある。

1.3 衛星リモートセンシングを活用した穀物モニタリング

農業は世界中で行われており、なかでも穀物は、他の農作物と比べて広大な土地で、ある特定の期間で毎年栽培されている。衛星リモートセンシングは、広域をまんべんなく観測することが可能である。また、衛星は周期的に地球を周回し、地表面を観測していることから、データの継続的な取得が可能である。以上の点より、穀物の生育をモニタリングする上で、衛星リモートセンシングは非常に有効であるといわれている。

1.3.1 衛星リモートセンシングを利用した単収推定

衛星リモートセンシングを活用した穀物モニタリングの研究はこれまで多く報告されてきた。代表的な研究は、単位面積当たりの収穫量（単収）推定である。穀物収量は、その年の気象条件によって大きく変動するため、単収推定の研究開発は食糧安全保障上、重要な取り組みである。

衛星リモートセンシングを利用した単収推定研究は数多くあるが、経験的手法を用いた研究が存在する。経験的手法は、過去のデータからある事象の傾向や関係を定量的に表すものである。衛星リモートセンシングから得られる植生指数と気象観測ステーションから取得した気温や降水量を説明変数とし、被説明変数である穀物単収を回帰分析で推定する。しかし、穀物生育は、土壌環境などの環境要因、品種改良や栽培技術の進歩によって大きく影響を受ける。穀物単収は、無数の要因によって大きく変動する複雑な問題のため、限られたデータで高精度に推定することは困難である。

1.3.2 作物生長モデルのデータ同化手法による単収推定

複雑な穀物生長メカニズムを解決するため、作物生長モデルと衛星データを組み合わせたデータ同化手法が研究されてきた。作物生長モデルは、植物の光合成によるバイオマス生産をモデル化し、日々の生長をシミュレーションするものである。気象データ、土壌データ、栽培管理パラメータや作物の品種パラメータを入力データとし、単収を推定することが可能である。気象データは、気温、降水量や日射量などの日別データである。土壌データは、層ごとの土壌水分量、pH、土壌構成比などである。栽培管理パラメータは、播種日、施肥量、灌漑管理など栽培に関わる詳細な情報である。品種パラメータは、発育速度、穂当たりの穀粒など品種ごとに設定するパラメータである。代表的な作物生長モデルとして、DSSATが挙げられ、穀物以外の野菜や芋類など幅広い作物のシミュレーションが可能である。作物生長モデルを利用して、農地の単収推定を実施するためには、パラメータのキャリブレーションが必要である。品種パラメータは、農業試験場のデータを用いた最尤法によるキャリブレーションで推定する。栽培管理パラメータは、農地や年によって異なるため、均一に与えることができない。この問題を解決するため、衛星データによる作物生長モデルの同化の手法が研究開発された。作物生長モデルは、衛星データから算出可能な葉面積指数（Leaf Area Index : LAI）を計算する。衛星データから得られるLAIを観測値とし、同化手法を適用することで、栽培管理パラメータを推定す

る方法が Fang, Liang & Hoogenboom (2011) や Dente *et al.* (2008) よって報告された。しかし、作物生長モデルの利用は、条件の厳しい入力データの整備や多くの情報を必要とするパラメータのキャリブレーションが必要なため、広範囲での適用や情報が十分に存在しない途上国での導入が困難であるといえる。

1.3.3 機械学習による穀物単収推定

あらゆる環境要因と穀物収量の複雑な関係をモデリングするため、機械学習による手法が近年提案されている。機械学習は、統計的手法と異なり、データから事象を予測することに重きをおいたものである。機械学習ではこれまで様々なアルゴリズムが開発され、サポートベクターマシンやニューラルネットなどが挙げられている (Mountrakis, Im & Ogole, 2011; Khairunniza-Bejo *et al.*, 2014)。衛星データから算出した植生指数と気象データを組み合わせた機械学習による単収推定手法は、Jiang *et al.* (2004); Li *et al.* (2007) によって報告されている。

機械学習は、取得可能なデータを用いて、作物単収を推定するモデルの構築が可能であるため、作物生長モデルのような入力データの厳しい制約条件は存在しない。また、統計的手法のように、入力データと単収の相関関係を高めるような説明変数の選定や形成といった作業は必要とせず、機械学習のアルゴリズムの中でその様な工夫がなされているため、煩雑な作業を必要としない。

1.3.4 衛星リモートセンシングを用いた栽培作物の分類

ある関心範囲において、作物の生産量を把握するためには、作物の単収だけではなく、栽培されている作物の空間分布を把握する必要がある。農業保険を設計・運用する上でも、作物の作付け・栽培状況に関する空間情報は重要であり、ベースリスクを考える上で重要である。衛星リモートセンシングでは、地表面の分光反射特性や合成開口レーダー (SAR : Synthetic Aperture Radar) を活かした土地被覆分類や栽培作物の分類に関する研究がなされている (Xie, Sha & Yu, 2008; Joshi *et al.*, 2016)。

MODIS では、全球土地被覆分類プロダクト MCD12Q1 が提供されている (Friedl *et al.*, 2010)。空間分解能は 500m となっており、2001 年から 2012 年まで各年で提供されており、土地被覆分類の代表的なプロダクトとなっている。土地被覆分類図では、都市域、落葉広葉樹林、針葉樹林、水域、耕作地など大まかな項目で分類されているが、作物種類ごとの分類がなされていない。本研究では、United States Department of Agriculture (USDA) によって開発された、数十種類の作物種類を 30 m 空間分解能で分類した土地被覆分類プロダクト、Cropland Data Layer (CDL) を用いて、トウモロコシ畑の空間分布を取得した。

1.4 本研究が提案する農業保険

今後、保険の需要がより高まるのは、人口増加が予想され、天候リスクに脆弱な途上国や新興国である。しかし、従来の農業保険では、逆選択やモラルハザードといった問題で、保険事業を持続的に実施することが難しい。査定へのコストも課題になることから、インデックス型保険の適用が良いと考える。

インデックス型保険の一番の課題はベースリスクである。Rao (2010) では、ベースリスクを表 1.2 のように分析している。本研究が改善するベースリスクは地理学的ベースリスクである。ベースリスクを低減する方法の一つとして、衛星データが有効だと考えられる。インデックス型保険には、単収や気象パラメータをインデックスにした、面積当たり収量インデックスと天候インデックスがある。天候インデックスは収量減収と強い相関関係にあるとは限らない。よって、衛星データから農作物の単収を推定するモデリングが有効であると考えられる。機械学習は、利用可能なデータを用いて推定モデルを学習できるため、データの制約条件が厳しい作物生長モデルと異なり、汎用性が高いといえる。整備されているデータは、国によって異なるため、各国でモデルを作成し、収量を推定・予測することが可能である。しかし、機械学習を適用したインデックス型保険の事例はまだ少ない。機械学習によって高精度な収量推定が可能となれば、インデックス型保険が抱えるベースリスクの課題の解決に期待できる。

また、単収推定モデルで単収の推定が可能となれば、損害型保険だけでなく、作物収入保険への適用も可能となる。作物収入保険は、価格リスクによる損失も考慮されているため、農家のニーズをより満たした保険商品といえる。

本研究では、途上国にでも導入を可能とする単収推定モデルを適用した収入保険の開発を目指す。そのために以下の三つの手法に取り組む。

表 1.2 インデックス型保険のベースリスク

ベースリスクの種類	単収インデックス	天候インデックス
地理的ベースリスク	対象地域が広域過ぎる場合、ベースリスクが高くなる可能性がある。また、農業生産性は地域的に均一ではない。	広域のエリアに対し、気象観測ステーションが少なく、ステーション間の距離が長い場合、ベースリスクは高くなる。
プロダクトベースリスク	作付け後から収穫時までのリスクをカバーしているため、収穫後で何かしらの原因で減収しても、補償されることはない。	天候に関わるリスクをカバーするため、病虫害や洪水などのリスクは補填されない。
プロダクトデザインベースリスク	平年単収と支払いが発生するトリガー単収の間で減収し、損害を受けても補償されない。	単収と完璧な相関は得られないため、ベースリスクはどうしても上がってしまう。

1.4.1 衛星データと機械学習を用いた単収推定手法

衛星データと機械学習による単収推定モデルを学習するための手法を開発する。衛星データは、アメリカ航空宇宙局（NASA：National Aeronautics and Space Administration）から配布されている MODIS の 8 日間コンポジット地表面反射率プロダクト（MOD09A1）から Enhanced Vegetation Index（EVI）を算出した。EVI は、雲の影響を受けるため、Wavelet 変換によるスムージング処理を施した。機械学習は、多くのアルゴリズムが開発されている。本研究では、ニューラルネットワークを適用する。その他のアルゴリズムでも推定モデルを構築し、推定精度を比較検証する。収量データは、アメリカ農務省（USDA：United States Department of Agriculture）が郡単位の農作物データを公開しているため、郡レベルの単収推定モデルを開発する。

1.4.2 単収推定のダウンスケーリング

本研究で利用する衛星データの分解能は 500 m となっており、郡の収量データよりも分解能が高い。また、コーンベルト周辺の郡はおよそ 50km の大きさがあるため、郡内でもトウモロコシの生育に偏りがあると考えられる。ベースリスクを改善するため、単収推定のダウンスケーリングを行う。本研究で学習した単収推定モデルを適用し、ダウンスケーリングの手法を開発する。そして、ダウンスケーリングした単収の評価を行う。

1.4.3 単収推定モデルの農業保険への適用

本研究で開発した単収推定モデルと収量ダウンスケーリングを農業保険の開発に適用する。USDA では、作物収入保険の保証データを郡単位で公開している。さらに、地域ごとに主要作物を栽培するのに必要な経費、作物価格や統計データが公開されている。本手法の農業保険を評価するため、これらの統計データを併せて、保険金による損失の補填状況の評価を行う。

1.4.4 本研究の対象

本研究の目的は、ベースリスクが低減されたインデックス型保険の手法開発である。さらに、今後、食料供給が逼迫すると懸念されるアジアの国々でも適用可能な手法を目指す。本研究では、アメリカの中西部に位置するコーンベルトで栽培されるトウモロコシを対象とする。

アメリカは、農業に関するデータ（作物ごとの収量、栽培地、農業保険など）が他国と比べて充実しており、機械学習を用いた研究手法の検証に向いている。アメリカでモデルケースを作り、評価することで途上国での導入について考察する。

さらにトウモロコシは、家畜飼料やバイオエネルギーに強く関連しているため、食料安全保障上、重要な穀物といえる。

1.5 本研究の独自性

本研究では、衛星データと機械学習手法を用いて、全米のトウモロコシ単収の推定モデルを開発する。これまで、機械学習を用いた穀物収量推定の研究は報告されているが、全米を網羅的に推定した研究はない。さらに、単収推定モデルを作物収入保険へと活用する。これまで、衛星観測した降雨量を天候インデックスにした例はあるが、衛星データと深層学習を組み合わせた単収推定モデルを農業保険に適用した例はまだない。本研究は、衛星による地球観測分野、機械学習のコンピュータサイエンス分野と農業保険の社会経済分野を融合させたものになる。

1.6 本研究の構成

1.3 に本研究で取り組んだ手法とその流れを示す。

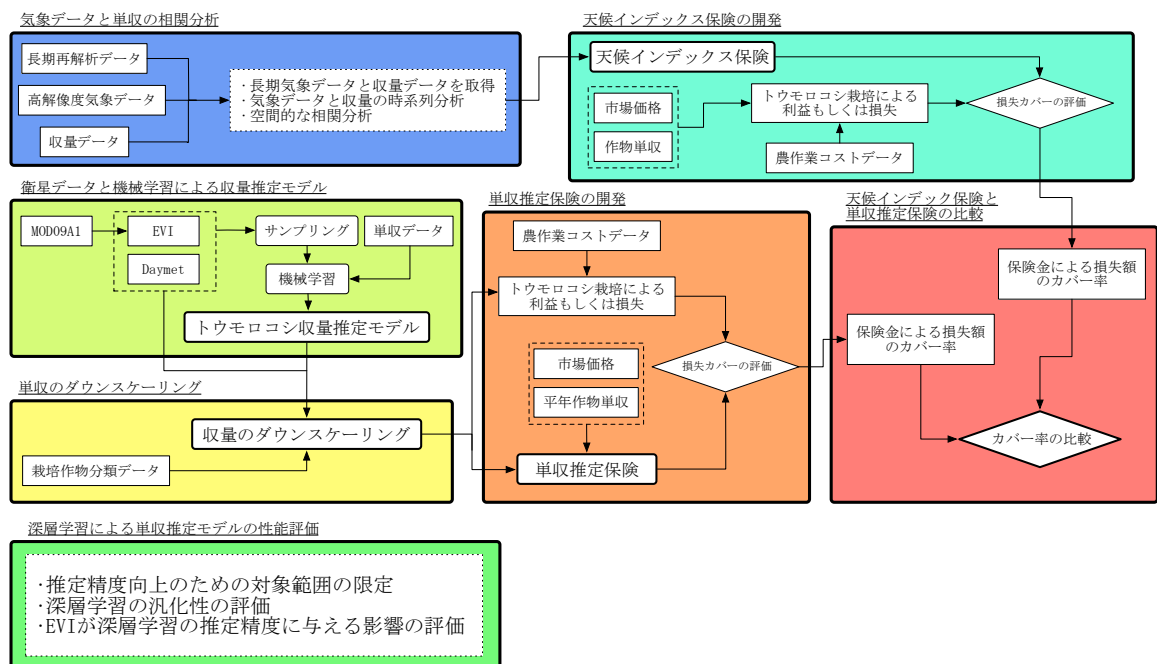


図 1.3 本研究で取り組んだ手法の流れ

第 2 章では、作物単収と長期再解析データ、全球高分解能気象データの相関分析を行い、天候インデックスの知見を得る。天候インデックス保険で扱うインデックスは、単収と高い相関関係にある必要がある。収量の減収につながる気象条件を気象データを処理して把握する。再解析データとは、過去の気象観測データと数値予測モデルを用いて、当時の大気や海洋の循環場や気温場などを再現したプロダクトである。6 時間単位で、気温、風速、降水量、風、湿度、日射量など様々な気象パラメータが数十年間用意されている。空間分解能は、 1.5° となってお

り、ベースリスクのため天候インデックスの適用には難しく、州レベルの分析となるが、気象パラメータと単収の関係を定量的に分析するために有効だと考えられる。本研究で扱う全球高分解能データは、Climate Research Unit (CRU) から取得した。CRU は、 0.5° となっており、郡レベルの分析に対応する。CRU による収量との相関分析を行い、再解析データの州レベルの分析と対比させ、ベースリスクに関する評価を行う。また単収データを取得し、時系列に分析することで不作と豊作のパターンを確認する。日本では、各県で圃場調査に基づいた水稲の作況指数を算出し、毎年の収量具合を把握している。アメリカには、このような作況指数が発表されていない。表 1.2 で示すとおり、穀物の単収は上昇傾向にあるため、このトレンドを補正した作物作況と気象パラメータの相関分析を行う。

第 3 章では、第 2 章の気象データと単収の相関分析結果をもとに天候インデックス保険を開発する。開発した天候インデックス保険の補償状況を評価するため、農家収入の保証状況を確認した。USDA が公開する単収と市場価格から、農家のトウモロコシ栽培による売上を算出し、トウモロコシ栽培に関わるコストを足し合わせることで営業利益を推計した。コストは、USDA が公開している統計データを用いた。そして、天候インデックス保険による保険金を合算することで利益を求めた。赤字であった営業利益が、天候インデックス保険によって黒字に転換できたかを試験することで、天候インデックス保険による農家収入の保証能力およびベースリスクの評価をおこなった。

第 4 章では、衛星データと機械学習を活用した単収推定モデル構築の開発を行う。機械学習への入力データは、衛星データから算出した植生指数と NASA が配布する気象データ Daymet を用いる。衛星データは Terra 衛星に搭載された MODIS の陸域プロダクト MO09A1, 8 日間コンポジット地表面反射率を利用する。MOD09A1 は、放射伝達モデルによって大気の影響が除去されているため、陸域の状態をはっきりと得ることが可能である。さらに植生指数 EVI を算出することで、本研究対象のトウモロコシの生育情報を得る。EVI は、赤 (620 nm - 670nm) と近赤外 (841 nm - 876 nm) のバンドを利用する。雲があると地表面に反射した太陽光が遮られ、EVI の値は極端に下がってしまう。雲によるノイズ除去を行うため Wavelet 変換を適用した。Daymet は、日別の気温、降水量、日射量、蒸気圧、湿度が空間分解能 1km のラスターデータとして用意されている。本手法で利用する入力データは、空間分解能 500m と 1km となっており、ターゲットデータである郡単位の単収データよりも分解能が高い。入力データをそのまま学習モデルに入力すると、トウモロコシ畑以外の情報が混入してしまうため、USDA が配布する 30m 空間分解能の栽培作物の土地被覆データ、CDL でマスキングを行った。CDL は、2008 年から北米全域で整備されているため、2008 年から 2013 年のデータを用いて、多層ニューラルネットワークを用いた深層学習によるトウモロコシ単収推定モデルを学習させた。全データの 8 割を学習に利用し、残りの 2 割のデータで推定精度を評価する cross validation を適用した。

第 5 章では、第 4 章で構築した深層学習による単収推定モデルの性能評価を行う。評価は、「適用範囲の限定」、「汎化性の評価」、「衛星データの有効性」の 3 つの観点で実験を行い、本研究の深層学習の有用性および課題について考察する。

第6章では、第4で学習させたトウモロコシ単収推定モデルに、1 km の EVI と気象データを入力し、CDL のトウモロコシ畑上の単収推定を行い、ダウンスケーリングする。1 km の収量データは公開されていない。ダウンスケーリングの精度を評価するため、1 km の単収を郡ごとに収穫量（単位面積当たり収量 × 面積）に再集計し、USDA の統計値と比較する。

第7章では、第4と第6章で開発した単収推定モデルを活用し、単収推定保険を開発する。単収推定保険の評価方法は、第3章の天候インデックス保険の評価方法と同様に市場価格やコストより営業利益を算出し、農家が被った損失が保険によって補償されたかを評価する。単収推定保険の設計は、アメリカで広く普及している収入保険（group risk program: GRP）を参考にする。

第8では、第3章と第7章で開発した天候インデックス保険と単収推定保険による、農家が被った損失の補填状況を比較評価した。評価には、損害保険の補填状況を定量的に評価するために算出されるカバー率を算出した。カバー率は、支払われた保険金を損失額で除算することで、計算される。天候インデックス保険と単収推定保険のカバー率を比較することで、保険による農家の収入保証を定量的に評価する。

第9章では、世界で頻発している自然災害の状況を地域ごとでとりまとめるとともに、各国の農業保険の導入状況について述べる。また、日本やアメリカの農業保険の導入状況や途上国・新興国の農業保険市場の成長性について述べ、今後、開発が予想される農業保険について考察する。そして、本研究で開発した農業保険が将来の農業保険導入にどのようにして貢献できるかの考察も行う。

第2章 気象データと単収の相関分析

2.1 分析の全体の流れ

第2章では、二つの異なる気象データセットとアメリカ政府が公開しているトウモロコシ単収データの相関分析を行う。気象データは、空間分解能が 1.5° と 0.5° のデータセットを50年程取得して用いた。

作物の単収は、天候不順などの影響を受けて不安定であるが、上昇のトレンドにある。よって、長期間の気象データと単収の相関係数を求めても有用な相関系は得られない。そこで、作況指数を算出し、気象条件と作柄の関係を定量的に分析した。

空間分解能 1.5° の気象データは、州レベルの単収データとの相関分析に用いる。まず、気象データを月別に積算し、標準化を施す。標準化したラスターデータを州ごとに集計し、平均値を求める。算出した平均値とトウモロコシの単収データの相関係数を計算する。さらに、月別の相関係数を州ごとに計算することで、気象条件と作柄の関係が地域的に異なるか確認する。

空間分解能 0.5° の気象データは、郡レベルの単収データとの相関分析に用いる。この気象データは月平均となっているので、標準化を施す。単収データは気象データと異なりCSV形式で取得しているため、ラスターデータに変換する。各グリッドで月別の相関係数を算出することで、州レベルの分析よりも詳細な相関分析を行う。

全体の分析の流れを図2.1に示す。主に2つの分析を行うことで、ベースリスクを低減した天候インデックス保険の実現性について考察する。

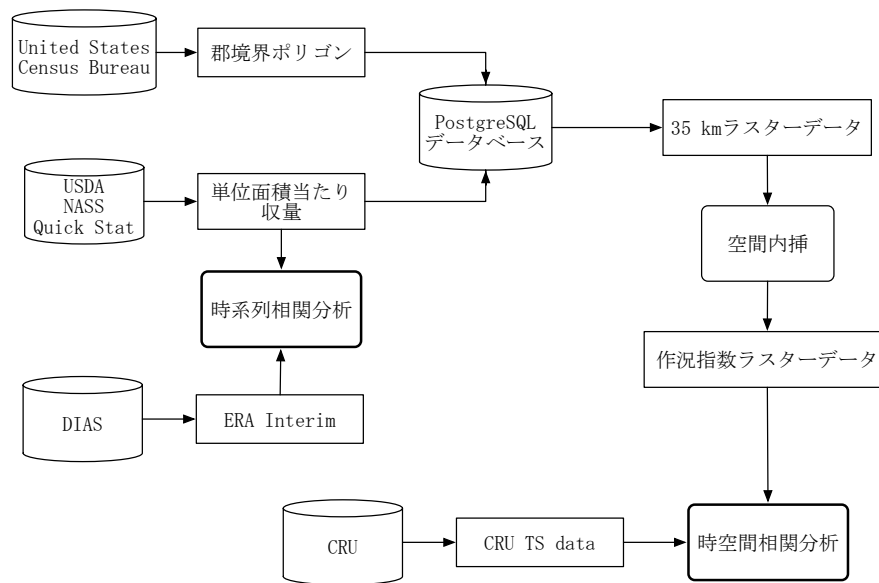


図 2.1 単収と再解析データの時空間相関分析の流れ

2.2 分析に利用したデータ

2.2.1 アメリカ農務省の作物統計データ

アメリカ農務省 (USDA: United States Department of Agriculture) の National Agricultural Statics Service (NASS) は、州や郡単位で集計されたあらゆる統計データを公開している。調査に基づいた 60 以上の作物の収穫量、栽培面積や収穫面積、家畜、農業で要した機械、人件費、施肥、灌漑、農薬や農業センサスなどが公開されている。主要穀物は、食用、サイレージ、飼料用などで分類されている。また、毎月 10 日に小麦、トウモロコシ、大豆、粗粒穀物、米、砂糖、畜産物、綿花の作況状況や需給予測が報告されている。アメリカだけではなく、世界中の穀物生育状況の最新予測も併せて公表されている。USDSA の報告書は、情報量と迅速性で最も信頼されており、穀物相場の関係者にとって重要な情報になっている。

本研究で取得した作物の単位面積当たり単収 (単収: yield), 作付け面積 (planted area), 収穫面積 (harvested area) は、NASS が運用している Quick Stats¹) より取得した。トウモロコシの単収と収穫面積を取得する際、Data Item 項目は、"CORN, GRAIN - YIELD, MEASURED IN BU / ACRE" と "CORN, GRAIN - ACRES HARVESTED" を選択した。データは 1960 年から取得した。

図 2.2 に 1960 年からのアメリカのトウモロコシの単収と収穫面積を示す。1960 年代から現在まで、単収はおおよそ 2.5 倍、収穫面積は 1.5 倍ほどに増加しており、単収の増加率が高い。図

¹<http://quickstats.nass.usda.gov/>

2.3に2008年のトウモロコシの単収 (bushels/acre) の分布図を示す。図2.4は、2008年のトウモロコシの収穫量 (bushels) を示す。単収は、地域によって差がみられるが、収穫量はイリノイ州を中心とした中西部が高い値となっている。つまり、トウモロコシの栽培地は、イリノイ州周辺に集中していることがわかる。トウモロコシは主にアメリカ中西部のコーンベルト (アイオワ州, イリノイ州, ネブラスカ州, ミネソタ州) で主に生産されており、世界を代表する穀物耕作地帯といえる。その他に大豆の主要産地になっている。

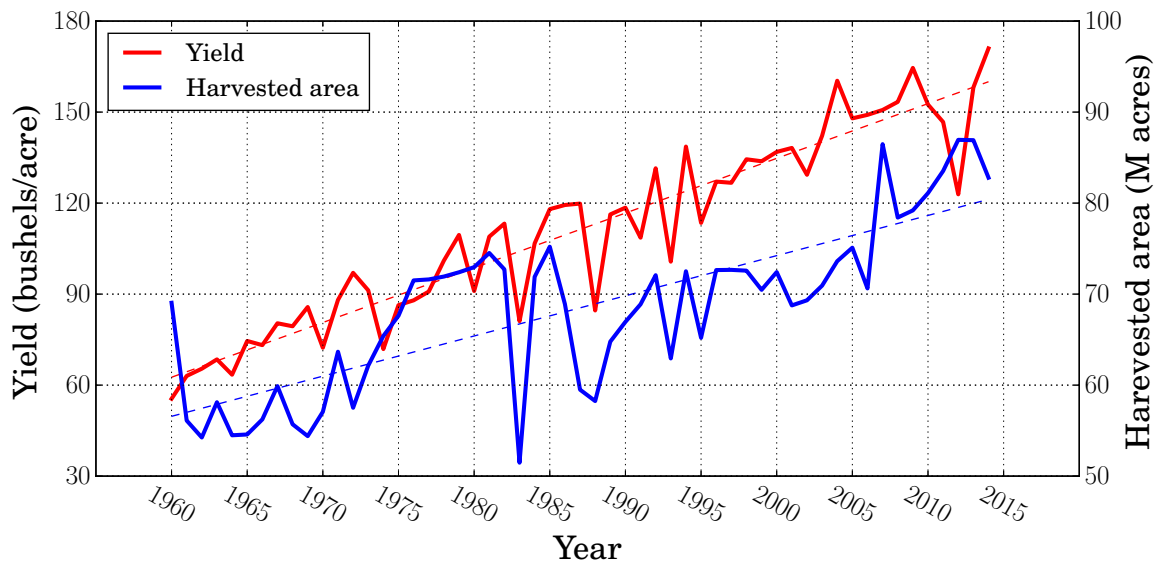


図 2.2 アメリカの単収及び収穫面積

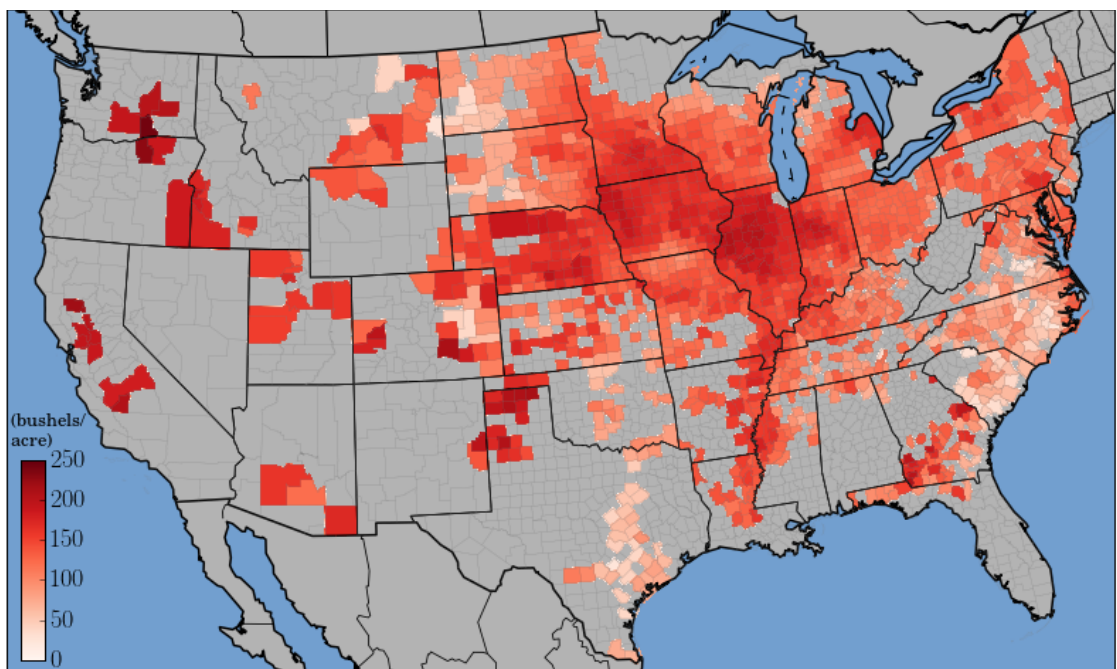


図 2.3 2008 年アメリカの郡レベルのトウモロコシ単収

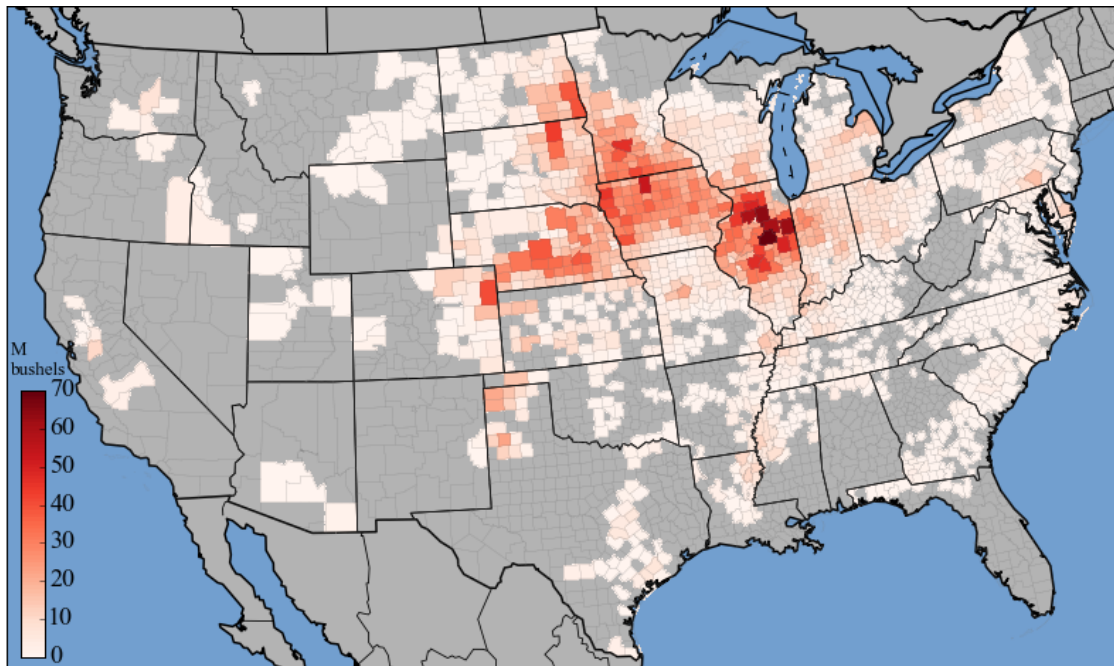


図 2.4 2008 年アメリカの郡レベルのトウモロコシ収穫量

2.2.2 長期再解析データ ERA-Interim

長期再解析データは、過去に観測された気象観測データと数値モデルを利用し、過去の大気の循環場や気温場を再現したデータである。半世紀前からのデータが用意されており、6時間単位で、気温、降水量、気圧、日射量、蒸気圧など様々な気象パラメータを扱うことができる。ヨーロッパ、アメリカ、日本の気象機関がそれぞれのデータプロダクトを提供している。本研究では、ヨーロッパの European Centre for Medium-Range Weather Forecasts (ECMWF) が提供する ERA-Interim を用いた。データセットは、地球環境情報統融合プログラム (DIAS: Data Integration & Analysis System) によってアーカイブされているため、そこから取得した。

ERA-Interim は、空間分解能が 1.5° で地球全体がカバーされている。本研究の対象値は北米のため、北米周辺でデータを切り取った。

2.2.3 高分解能全球気象データ CRU

CRU は、イギリスの University of East Anglia の Climate Research Unit が配布している全球の高分解能の気象データである。世界各地の気象観測所の観測データを利用し、データの不均一性を取り除き、観測点以外の値を内挿することで、全球のグリッドデータを構築した。期間は 1901 年から現在までとなっており、月別のデータが分解能 0.5° で整備されている。気象パラメータは、平均気温、最低気温、最高気温、気温日較差、降水量、蒸気圧、被雲率、蒸発

散，降水頻度となっている。CRU は，ERA-Interim より空間分解能が高く，郡レベルの単収との相関分析の利用が可能である。分解能の異なる気象データとの分析結果を比較することで，ベースリスクの評価を行う。

2.3 分析のためのデータ処理

2.3.1 作況指数の算出

図 2.2 より、単収は上昇のトレンドにある。これは、栽培技術の向上による影響だと考えられる。よって、気象パラメータとの相関分析を行う際、単収の上昇トレンドの影響を取り除く必要がある。本研究では、以下の式 (2.1) より、アメリカトウモロコシの作況指数を算出し、各年の作柄を求めた。

$$I_t = \frac{y_t}{\bar{y}_t} \times 100 \quad (2.1)$$

I_t は t 年のトウモロコシ作況指数、 y_t はトウモロコシ単収、 \bar{y}_t は 5 年移動平均である。 \bar{y}_t を平年水準値とし、平年作を基準 100 とするように変換した。日本の水稻作況指数も同様の方法で作柄を指数化し、天候不順が水稻の作柄を把握して、需給計画に反映している。日本においても、単収は技術改良（品種構成、栽培技術等の変化）を考慮するため、スプライン関数などを用いて単収をスムージングし、平年の水準値を算出している。本研究では、簡易的に推定するため、5 年移動平均を計算した。アメリカの農業保険の保険料算出の際も、移動平均が利用されている。

2.3.2 面積按分による作況指数のラスタータ化

本研究では、アメリカのトウモロコシと気象データとの関係を時系列と空間的に分析する。USDA が提供する作物データは CSV 形式のテーブルデータで、再解析データと CRU はラスタータデータとなっており、二つのデータ形式は異なる。両データの分析を簡便にするため、トウモロコシ単収データをラスタータ化した。

処理の流れを図 2.1 に示す。処理の流れは、アメリカ国勢調査局から郡境界のポリゴンデータを取得、USDA NASS の Quick Stat からトウモロコシ収穫量（収穫面積 × 単位面積当たり単収）と収穫面積データを取得し、PostgreSQL のデータベースに取り込んだ。アメリカ政府が公開しているデータは、Federal Information Processing Standard (FIPS) によって、全ての州と郡に共通コードが割り振られている。FIPS に基づき、郡境界ポリゴンデータとトウモロコシ単収データをテーブル結合した。PostgreSQL には、PostGIS プラグインが用意されている。PostGIS とは、オープンソースの地理空間情報システム (GIS: Geographic Information System) であり、ベクター形式のデータ処理に必要な処理ツールが用意されている。

ベクターデータ化した郡レベル収穫量データを単収のラスタータデータに変換するため、面積按分を行った。図 2.5 に面積按分の一例を示す。コーンベルト周辺の郡の面積は、およそ 1300 km² となっているため、35 km × 35 km のグリッドを作成し、郡の境界ポリゴンにインターセクト処理を行う。グリッドによって分割された郡のポリゴンの面積比を計算し、郡の収穫量と収穫面積に乘算することで、グリッド単位の収穫量と収穫面積を取得する。収穫量に収穫面積

を各グリッドで除算することでグリッドの単収データを得る。図 2.5 の中央に位置するグリッドは 4 つの郡がまたがっている。このグリッドの面積按分の計算方法を式 (2.2) に示す。

$$P = \sum_{i=1}^4 \frac{I_i}{C} x_i \quad (2.2)$$

P は面積按分によって算出される収穫量もしくは収穫面積、 I はインターセクトして作成されるポリゴン面積、 C は郡の面積、 x は郡の収穫量もしくは収穫面積である。

さらに、面積按分してグリッド化したトウモロコシ単収データをラスターデータに変換した。ラスターデータへの変換は、GDAL (Geospatial Data Abstraction Library) を利用した。GDAL もオープンソースの GIS ライブラリであり、様々なラスターデータ形式をサポートしており、あらゆるオープンソース GIS のラスターデータ処理に利用されている。

USDA が提供する郡レベルの作物単収データは、年によって欠損しているデータがあるため、内挿を施した。データが欠損している郡は、隣接している郡の単収の平均、もしくは州レベルの単収データの値を代入して補間した。補間した単収データを式 (2.1) より郡レベルの作況指数を算出した。




図 2.5 面積按分の例

2.3.3 暖かさ指数と露点差の算出

気象データから作況指数とのより強い相関関係を得るため、植生の成長に強い関係を持つとされている暖かさ指数と露点差を算出する。

暖かさ指数は、Kira (1948) によって提案された温量指数の一つである。月の平均気温が 5°C を越える月を植物が生育できる期間として、気温から 5° を減算して積算される。逆に、 5° 未満の月を非生育期間と仮定して、積算が無視される。本研究では、ERA-Interim の平均気温を用いて暖かさ指数を算出した。

露点差は、気温と露点温度の差のことを指し、大気の湿り具合を表す。水蒸気を含んだ空気は、飽和水蒸気圧が低下することによって、ある温度で水滴が出来き、凝結が発生する。この凝結する温度を露点温度という。露点温度高いということは、空気が含む水蒸気量が多いことになる。よって、露点温度が下がり、露点差の値が大きくなると大気が乾燥していることを示す。作物の生長は、大気の湿潤具合に敏感であるため、気象条件と作柄の相関関係を分析に露点差は有効であると考えられる。ERA-Interim では、露点温度が提供されているため、露点差を算出した。

2.3.4 気象データの標準化

本研究では、気温、降水量や日射量など様々な気象パラメータを扱う。各パラメータは単位が異なる物理量であり、それぞれが示す値の作柄への影響は異なる。よって、各気象パラメータを標準化した。標準化は式 (2.3) で行った。

$$z_t = \frac{x_t - \mu_t}{\sigma_t} \quad (2.3)$$

z は標準化した値、 t は気象データの積算もしくは平均した月、 μ_t は月 t の気象パラメータの平均、 σ_t は月 t における気象パラメータの標準偏差である。標準化することで気象パラメータは、平均を 0、標準偏差が 1 となる正規分布に従うデータへと変換される。ERA-Interim と CRU を標準化することで、天候不順の評価が可能となり、作柄との相関分析に有効になると考えられる。

2.4 作況指数による作柄の評価

2.4.1 作況指数と実際に報告された単収実績の関連性

図 2.6 に、式 (2.1) で算出したアメリカの主要穀物（トウモロコシ、大豆、小麦）の作況指数を示す。1970 年から作況指数が 90 以下になったシーズンは 6 回ほど発生した。表 2.1 に減収となった年と原因を示す。トウモロコシと大豆は、作況指数の動向が似ており、相関係数 $R = 0.753$ となっている。トウモロコシは 4 月から 5 月が播種期で収穫期が 9 月から 11 月、大豆は 5 月から 6 月で収穫期が 9 月から 11 月となっておりクロップカレンダーが類似している。また、大豆の主要産地もコーンベルトに位置しているため、トウモロコシと大豆の単収は、同じ天候災害の影響を受けやすい。アメリカで栽培されている小麦の 4 分の 3 は、秋播き小麦のためクロップカレンダーは大きくことなる。小麦の主な生産地は、カンザス州を中心とするグレートプレーンズ（大平原地帯）である。州単位で算出した作況指数をクラスタリングしたところ、イリノイ州、インディアナ州、アイオワ州、カンザス州、ケンタッキー州、ミズーリ州、ネブラスカ州、オハイオ州、サウスダコタ州、テネシー州が同一のクラスタに分類され、コーンベルトとほぼ一致した（図 2.7）。これまで、大規模な天候不順が発生する度、世界最大のトウモロコシ産地は大きな被害を受けたのが、作況指数を用いることで把握できる。

図 2.8 に本研究で算出した郡レベルのトウモロコシ作況指数のラスターデータのヒストグラムを示す。作況指数を算出した期間は 1960 年から 2013 年である。最頻値となっているのは作況指数が 100 付近であり、本研究の作況指数算出方法でも平年水準を推定できていることがわかる。

以上より、作況指数は、過去に発生した天候不順が影響で減収した作物の作柄を表していることが確認できた。天候不順の影響を受ける作柄を分析するため、作況指数は有効な指標であると考えられる。

2.4.2 作況指数のラスターデータによる地域的な作柄の把握

図 2.9 に表 2.1 で示す年におけるトウモロコシ作況指数のマッピングを示す。100 を平年水準の単収とし、100 以下は平年水準よりも作柄が悪く、100 以上は作柄が良かったことを示す。値の範囲を 40 から 160 までとって表現しているが、最も値が低いところで 20 を下回る。カラースケールの都合上、範囲外となっているデータは、40 もしくは 160 を代入して表現している。どの年も深刻な被害をもたらしたが、作況指数の落ち込みの空間的分布は異なる。また、作況指数をラスターデータにすることで、地形による影響も作柄に影響を与えていることが推測できる。例えば 2012 年のサウスダコタ州では、州の対角線を沿って作況指数が落ち込んでいるのが分かる。この範囲は、ミズーリ川が位置しており、周辺は耕作地帯になっている。2012 年の干ばつが影響で、ミズーリ川から灌漑していた農地の単収が急激に落ち込んだか可能性が強いと考えられる。

以上より、作況指数をラスターデータで扱うことで、減収している地域を的確に把握することができた。




図 2.6 アメリカの主要穀物の作況指数

表 2.1 アメリカのコーンベルトで発生した大規模な天候不順

年	減収原因
1974年	コーンベルトで作付け遅れ，干ばつ，早霜が発生した。
1983年	1982年に20世紀最大規模とされるエルニーニョ現象が発生し，1983年に熱波が襲来した。
1988年	50年ぶりの大干ばつが発生した。
1993年	コーンベルト北西部で長雨と洪水が発生した。
2002年	干ばつが発生した。
2012年	歴史的な大干ばつが発生した。

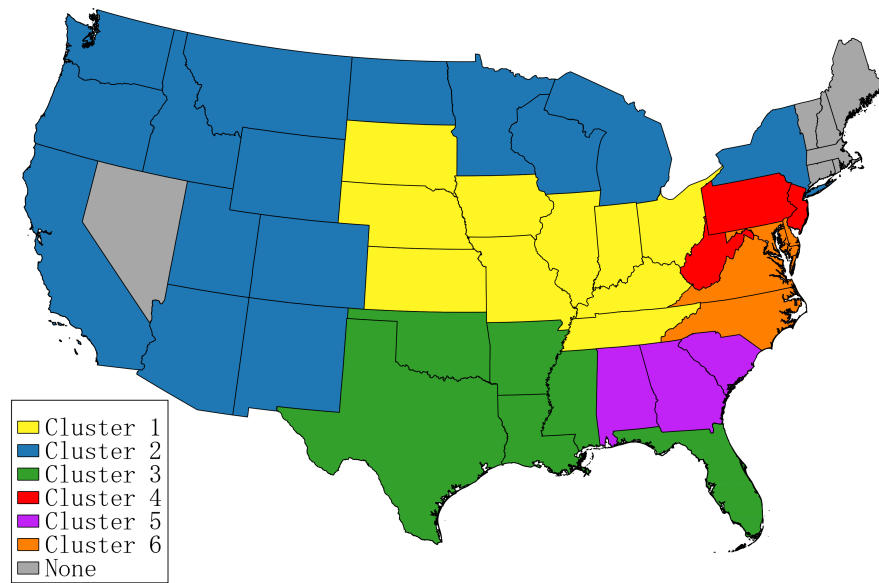


図 2.7 トウモロコシ作況指数をクラスタリングした分布図




図 2.8 1960 年から 2013 年のトウモロコシ作況指数のヒストグラム

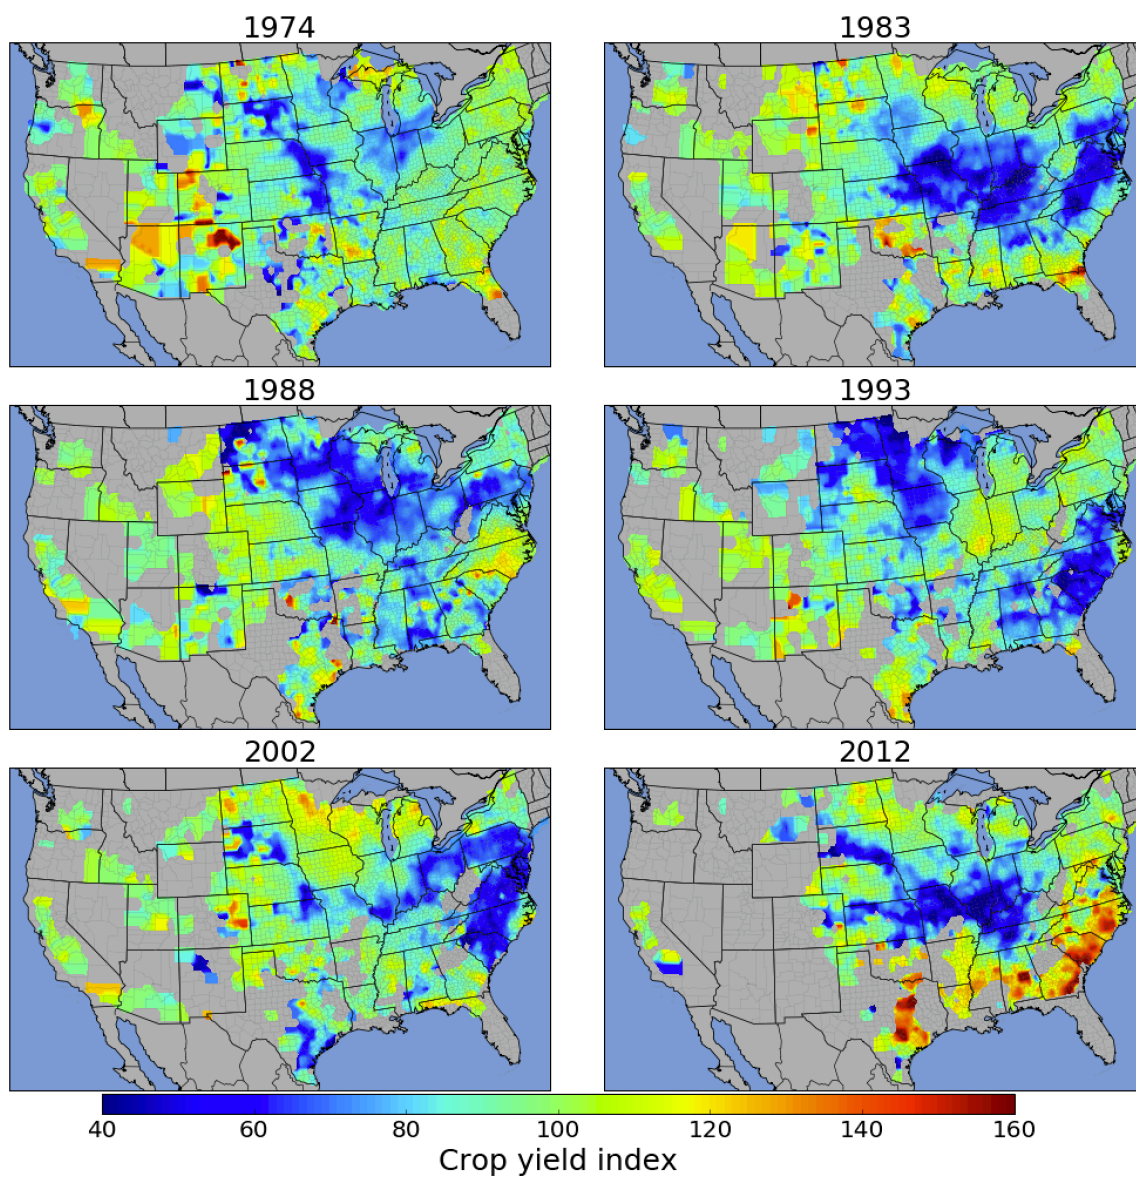


図 2.9 凶作シーズンだったトウモロコシ作況指数

2.5 ERA-Interim を用いた州レベルの相関分析

ERA-Interim と本研究で作成した州レベルのトウモロコシ作況指数との相関分析を行った。ERA-Interim の気温、気圧、日射量、露点差、降水量、温量指数を月積算し、州ごとの平均値を集計した。各月の積算気象パラメータと作況指数の相関係数を求めた。図 2.10 に月単位相関係数の結果を示す。

トウモロコシの主要生産地であるイリノイ州、インディアナ州、アイオワ州、カンザス州、ケンタッキー州は各月の相関係数に同様の傾向がみられた。7月から8月の夏季にかけて気温、日射量、露点差や温量指数と作況指数には負の相関が得られた。逆に降水量は正の相関がみられた。つまり、夏季期間中において、気温が高く乾燥していると、干ばつになり大きく減収するという現象が相関分析の結果で得られた。さらに7月の降水量も作柄に影響することがわかった。また、気温や露点温度から算出した温量指数や露点差は、より強い相関関係が得られたことより、気象パラメータを直接扱うのではなく、植生の成長との関係が強いデータに変換することが有効であることが示された。

ノースダコタ州、サウスダコタ州、ウィスコンシン州などの北部に位置する州は、コーンベルトの州とは異なる相関係数のトレンドがみられた。北部の州は、コーンベルトの中心地域から 500 km 以上離れており、地域の気象特徴が異なるため、コーンベルト地域の不作のシーズンと気象条件が連動していないということが考えられる。

2.5. ERA-INTERIM を用いた州レベルの相関分析

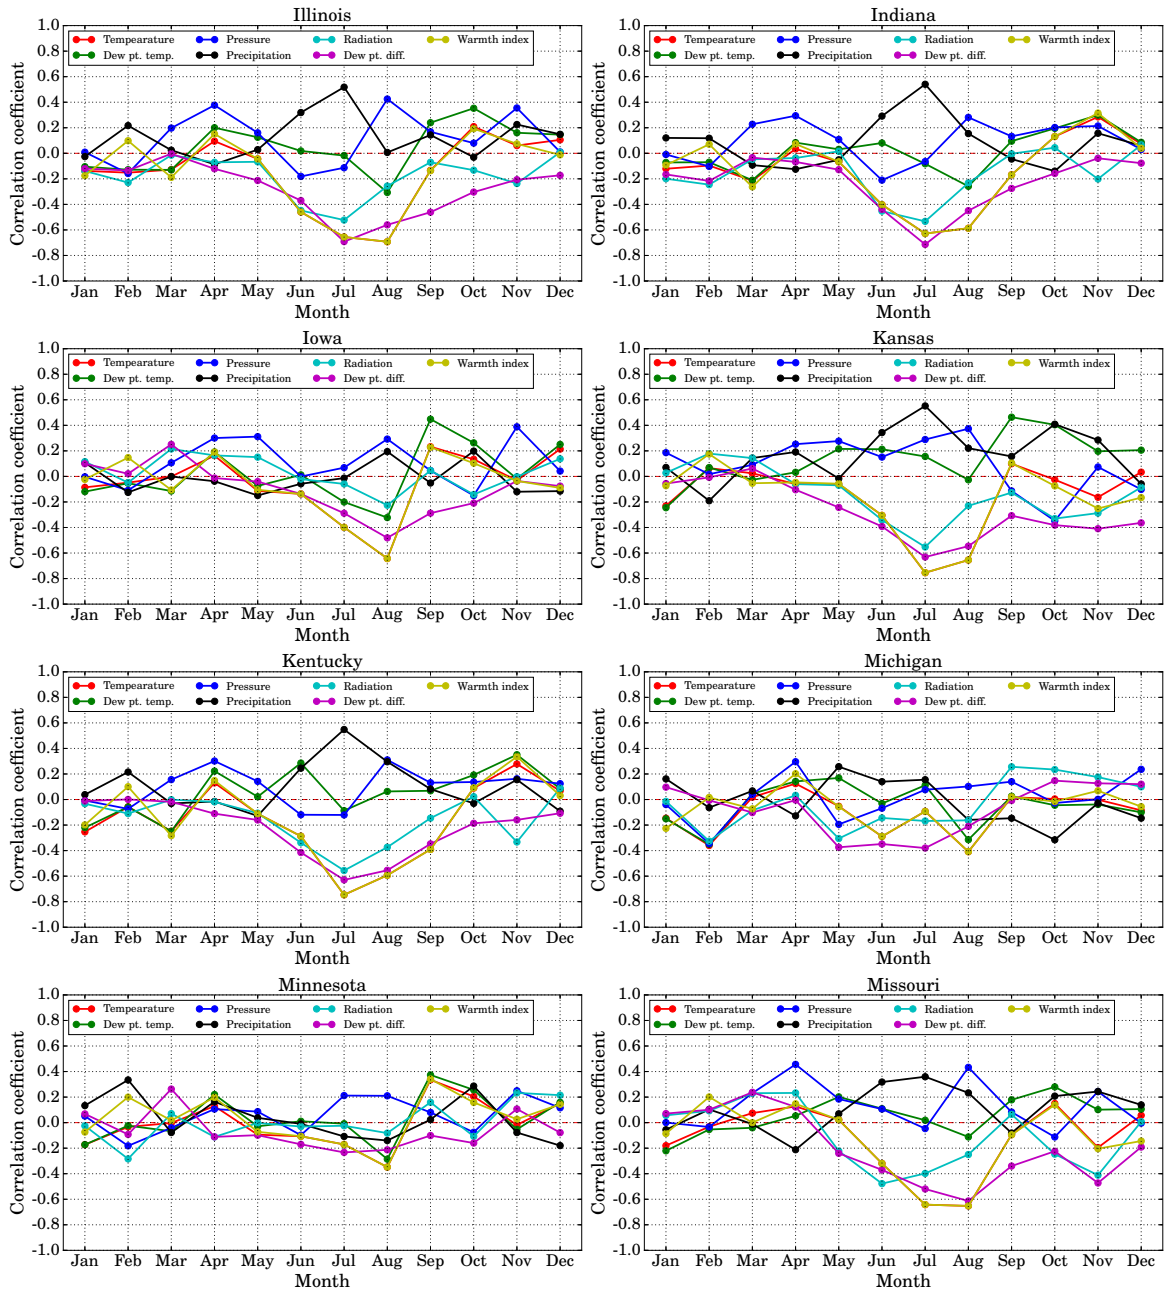


図 2.10 トウモロコシ作況指数と月積算の ERA-Interim との相関分析

2.6 CRU を用いた郡レベルの相関分析

CRU と トウモロコシ 作況指数 による の郡レベルの相関分析を行うことで、地域ごとの気象データと トウモロコシ 単収の相関関係を確認した。CRU は、最大気温、最低気温、降水量と蒸発散量を利用した。さらに CRU は、各月の平均データである。50 年分のデータを標準化し、2.3.2 でラスターデータ化した作況指数との相関をグリッド単位で算出した。結果を図 2.11 から 2.22 までに示す。

結果、月によって気象パラメータと単収データの相関は地域ごとに異なることがわかった。1 月から 5 月の期間では、有意な相関関係はアメリカのどの地域でも確認されなかった。6 月には、テキサス州、ミシシッピ州、アラバマ州、ジョージア州などの地域において、最高気温と蒸発散量と負の相関関係がみられた。降水量は逆に正の相関関係があった。7 月では、最高気温と蒸発散量がコーンベルトと東海岸、東南部において負の相関関係がみられた。降水量は正の相関があったが、最高気温と蒸発散量と比較すると相関関係は小さいことがわかる。8 月では、最大気温と蒸発散量が同様の地域で負の相関がみられたが、7 月ほど強くはみられなかった。つまり、夏季期間において、最大気温と蒸発散量が負の相関があり、降水量は正の相関があった。しかし、北部やウェストバージニア州などの地域では、相関関係がみられない場合もあった。

USDA によるとアメリカのトウモロコシの生育期間は 4 月から 11 月の間とされているが、本研究の相関分析では、6 月から 8 月の間で気象データと トウモロコシ 作況指数の相関関係が確認された。また、地域によって相関の度合いは異なり、主要なトウモロコシ生産地以外の地域では、有意な相関関係は確認できなかった。

気象データは、最大気温と蒸発散量が 6 月から 8 月の期間でほぼ同じコーンベルト地帯で負の相関が確認された。最低気温は、最大気温程ではないが負の相関が確認された。9 月では、ノースダコタ州など北部の地域で正の相関関係がみられる。降水量は、最大気温と蒸発散量と逆の結果が得られた。6 月から 7 月の期間で最大気温、蒸発散量の同様の地域で正の相関関係が得られた。以上より、気象パラメータによっても、期間や地域でトウモロコシの作柄と異なる相関関係があったことが確認された。

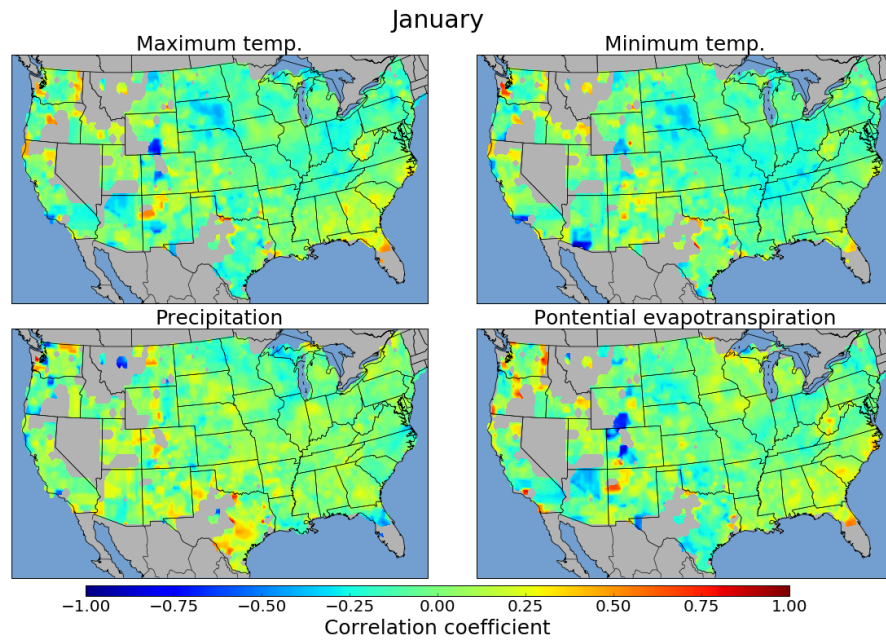


図 2.11 CRU と作況指数の相関分析（1月）

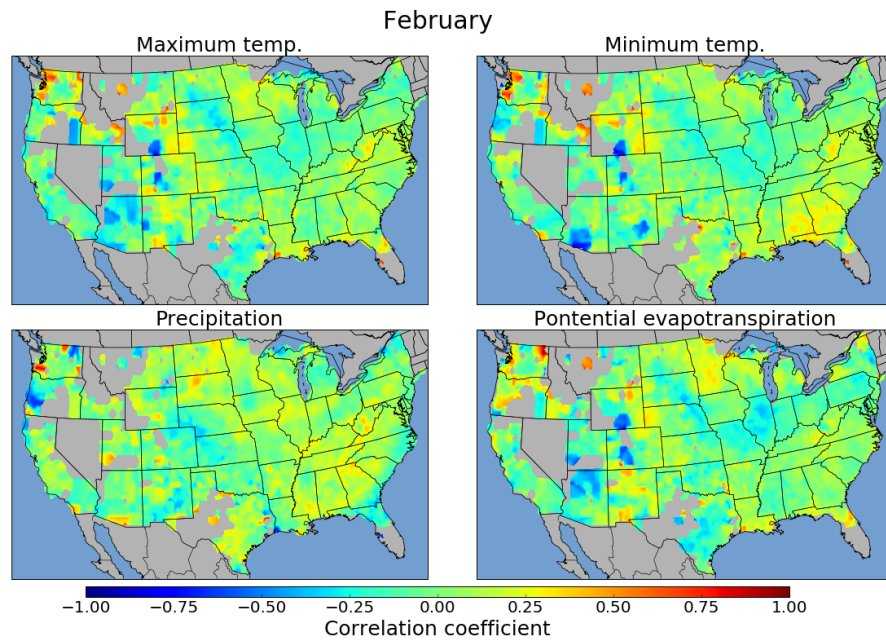


図 2.12 CRU と作況指数の相関分析（2月）

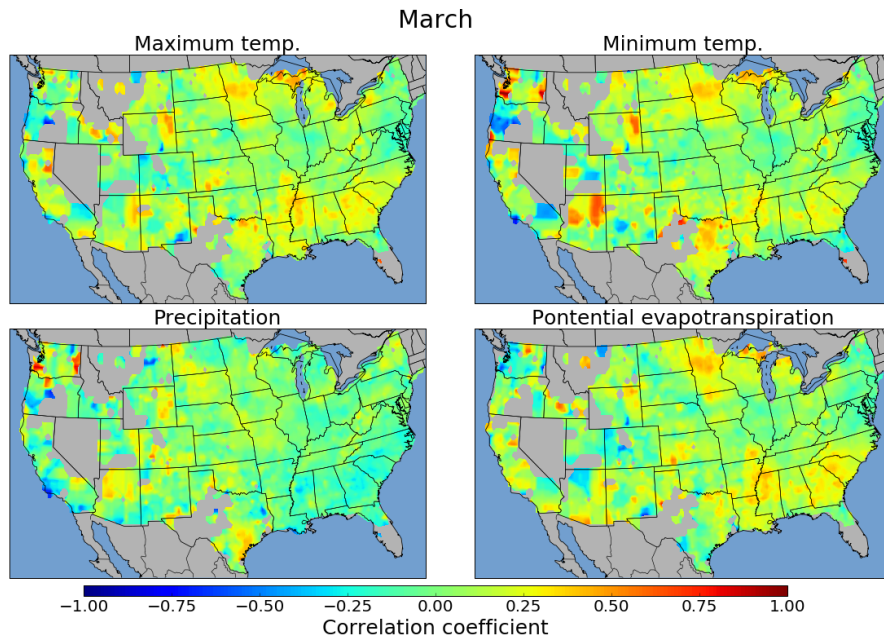


図 2.13 CRU と作況指数の相関分析（3 月）

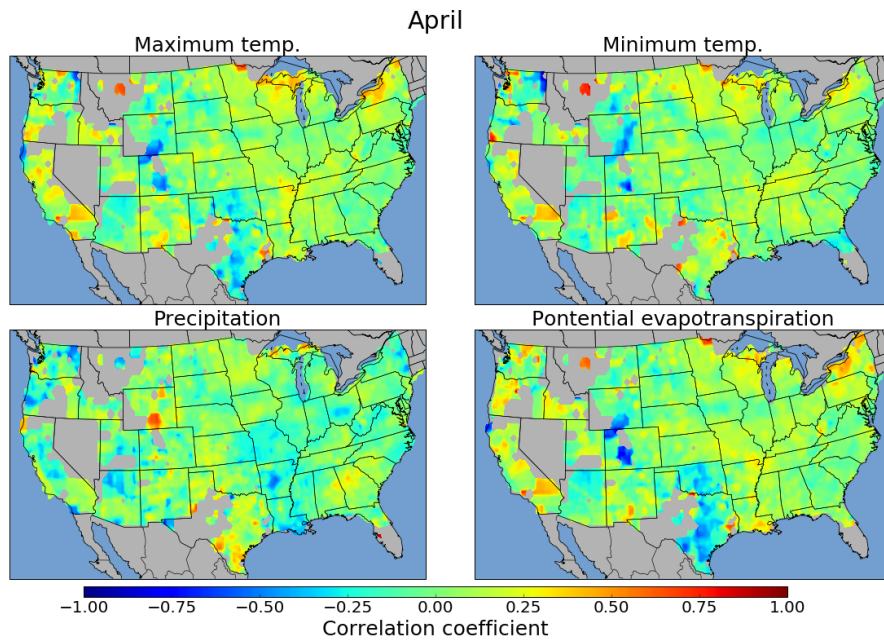


図 2.14 CRU と作況指数の相関分析（4 月）

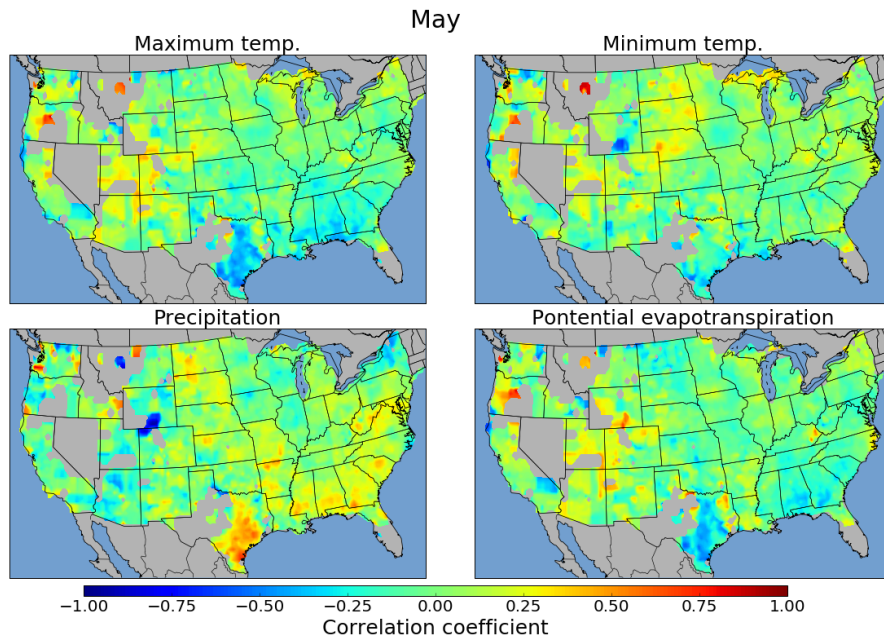


図 2.15 CRU と作況指数の相関分析（5月）

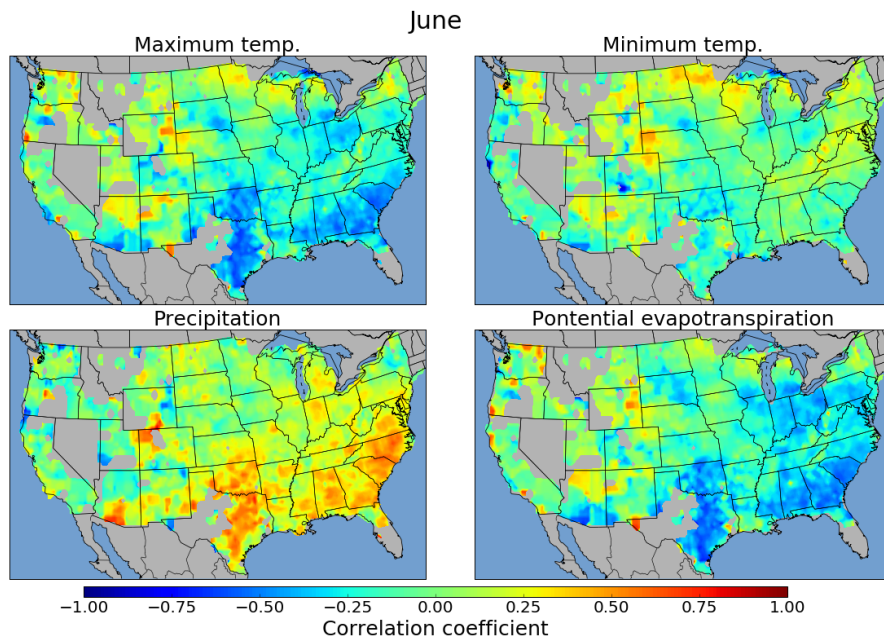


図 2.16 CRU と作況指数の相関分析（6月）

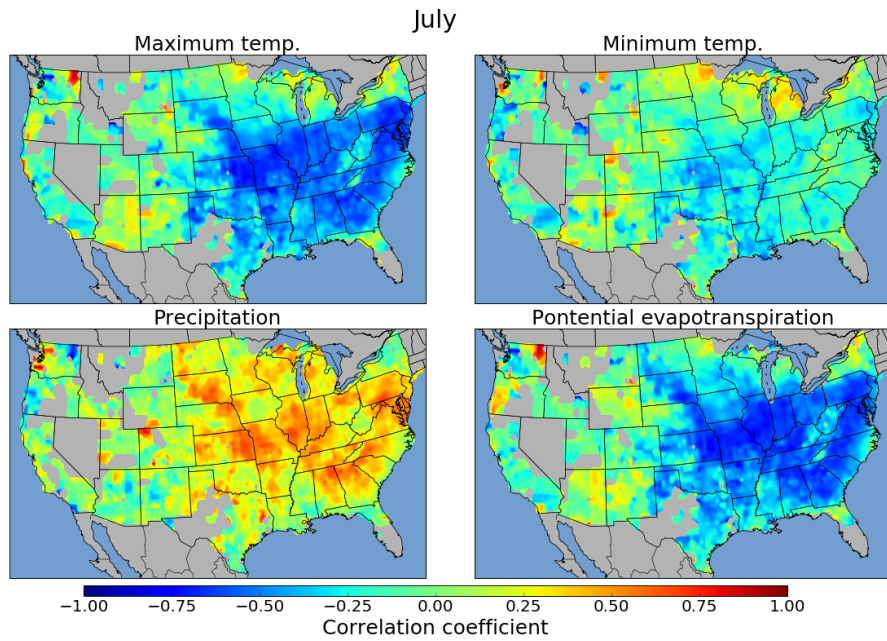


図 2.17 CRU と作況指数の相関分析（7月）

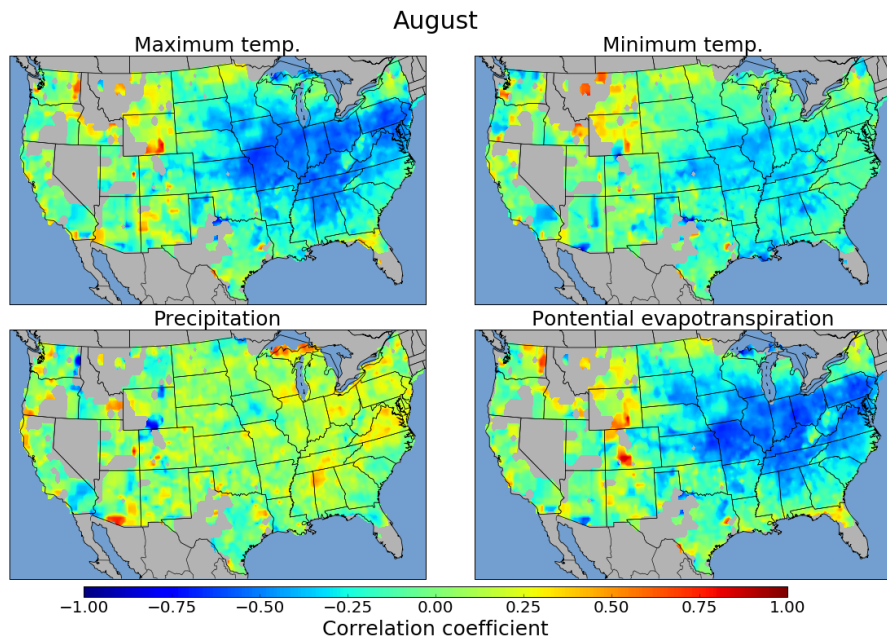


図 2.18 CRU と作況指数の相関分析（8月）

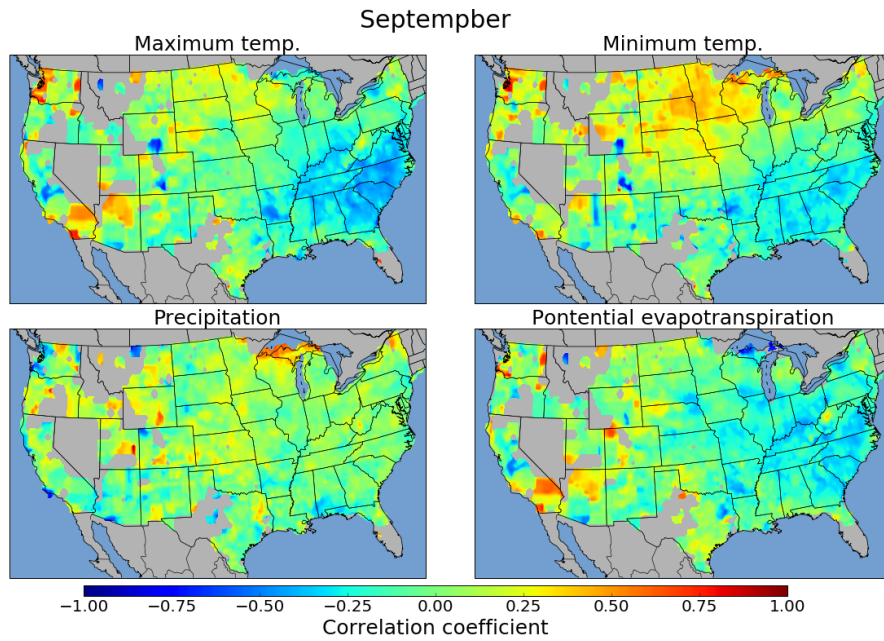


図 2.19 CRU と作況指数の相関分析 (9 月)

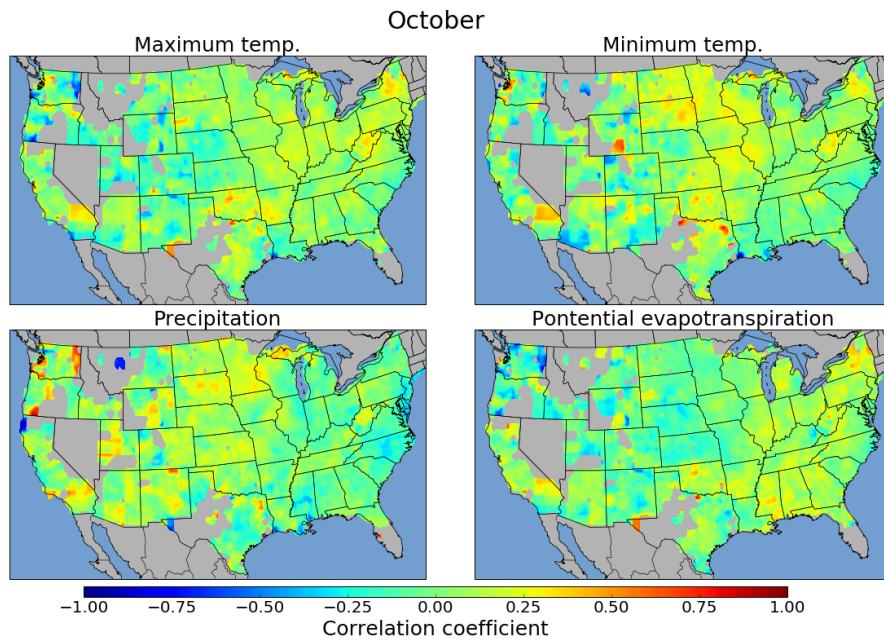


図 2.20 CRU と作況指数の相関分析 (10 月)

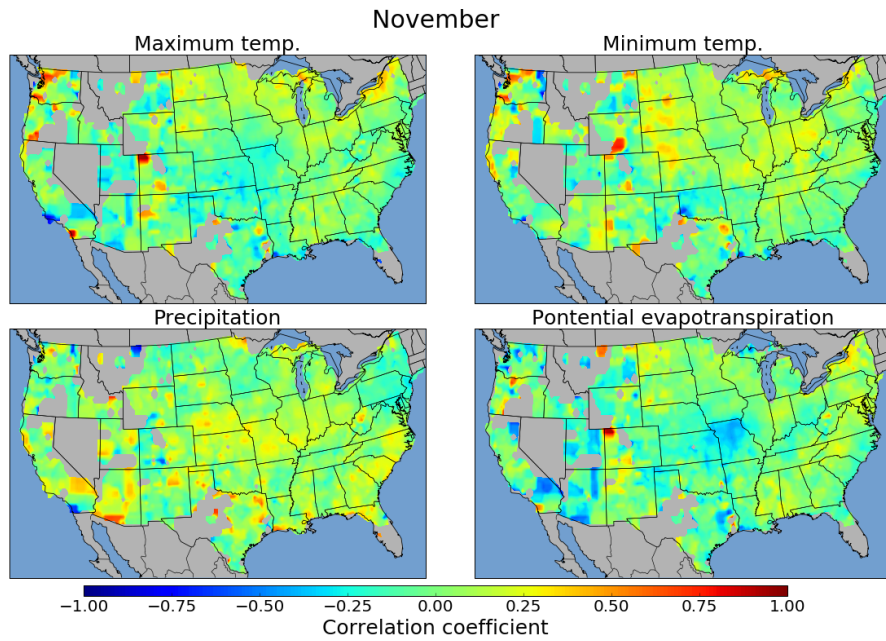


図 2.21 CRU と作況指数の相関分析（11月）

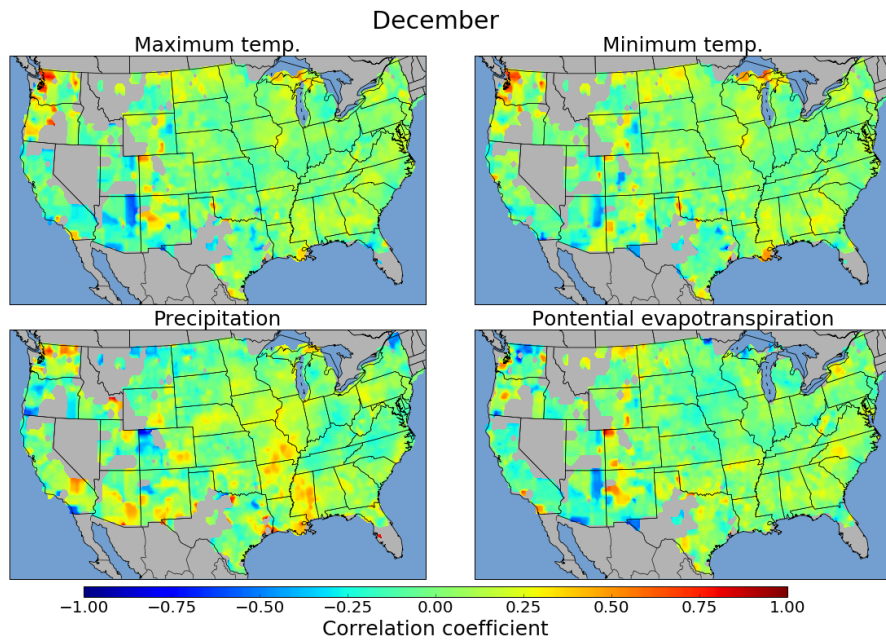


図 2.22 CRU と作況指数の相関分析（12月）

2.7 考察

2.7.1 作況指数による作柄の評価

単位面積当たり単収から作況指数を算出することで、毎年の作柄を定量的に評価することが可能となった。また、作況指数のラスターデータ化は、天候不順による作柄の落ち込みを地域的に把握するために有効であることが確認できた。さらに過去数回にわたって発生した大干ばつなどによる凶作シーズンにおいても、より深刻であった地域が推測できた。農業保険の設計には長期間のデータを分析する必要があるため、作況指数はインデックス型保険の適用に有用であると考えられる。

2.7.2 複数気象データセットを用いた分析の考察

2.5と2.6のそれぞれで気象データと単収の州および郡レベルの相関分析を行った。両者の分析結果において、夏季における気温が作柄と負の相関があり、降水量とは正の相関関係があったことがわかった。つまり、トウモロコシは夏季期間の干ばつによって、単収が減収する可能性が高いということがいえる。

また、単純に気象パラメータを分析するよりも、温量指数や露点差などデータに変換することでより高い相関関係が得られた。これは、作物単収に関係が強い特徴量を人間の手によって形成した工程といえる。ベシスリスクを低減するためには、このような特徴量抽出は有効であると考えられる。しかし、このような特徴量形成は、無数の組み合わせがあり、数多く得るのは困難である。露点温度は、気象観測ステーションで一般的に観測されている気象パラメータではないため、作物作柄と相関関係の強いインデックスを作成するには限界がある。

さらに、郡レベルの相関分析を行うことで、気象パラメータと単収は州の中でも地域で異なる相関関係を持つことがわかった。コーンベルトを中心とした中西部では、単収は気象パラメータと相関関係がみられたが、北部や西海岸の地域では、相関関係は得られなかった。これは、地域によって気象条件が異なることが考えられる。よって、天候インデックス保険を設計する場合、地域ごとに閾値を設定する必要があるが、相関関係がみられない地域においては設計が難しいことが考えられる。

2.7.3 気象データセットを用いた天候インデックス保険に関する考察

長期間の気象データと作況指数の相関分析によって、気象パラメータと作柄の地域的や特定期間の相関関係が明らかになった。天候インデックス保険を設計する際、気象パラメータと作物単収の作柄の相関関係が強い組み合わせを割り出し、インデックスを設計する必要があるが、アメリカ州内でも地域ごとに行う必要がある。また地域によって、相関関係が得られなかった場所もあるため、天候インデックスの適用は難しいことが考えられる。よって、気象条件が作

物の作柄に与える影響は、地域によって異なるため、天候インデックス保険は地域ごとのオーダーメイドが必要となる。

さらに気象パラメータを温量指数や露点差などに変換した方がより強い相関が得られたように、特徴量を形成することで、より良いインデックスが開発できることに期待できるが、その組み合わせは無数にあるため多くの労力を要する。また、気象観測ステーションで観測される気象パラメータは限られているため、必ずしも同様のインデックスを作成できるとは限らない。

以上より、天候インデックス保険を設計する場合、気象条件と作柄の相関関係を地域ごとに分析する必要があるが、取得可能な気象データは地域によって異なるため、あらゆる地域で適用可能な手法を確立することは困難である。

第3章 天候インデックス保険の開発

3.1 既存の天候インデックス保険の開発方法

多くの途上国では、限られた農業の商業化や小規模な農地面積などといった特徴を有している。よって、それらの国において、査定によって保険金の支払いを決定する従来型保険は、持続的導入への障壁であると考えられている (The World Bank, 2011)。天候インデックス保険は、そのような課題の解決を期待された保険商品であり、農業生産ロス及び農家の経済的損失に強く相関を持つ天候リスクの責任引き受けを行うために、低所得国で導入されてきた (Collier, Skees & Barnett, 2009)。

天候インデックス保険の長所は、保険運用に関わるコストの低さ、支払いタイミングの早さが挙げられる。大きな課題はベースリスクとなっており、ベースリスクが原因で途上国への普及が滞っていることが考えられている。ベースリスクを低減するためには、単収の減収と相関関係が強い気象パラメータ（気温や降水量など）の条件（干ばつや高温など）をインデックス化する必要がある。図3.1は、降水量をインデックスとした最もシンプルな例であり、干ばつが発生した際に保険金を自動的に支払う天候インデックス保険となっている。P₁ および P₂ が保険金支払いの閾値となっている。P₁ と P₂ は、各地域の作物に対してそれぞれ設定する必要がある。各地域によって栽培に要するコストが異なるため、減収して被る損失を適正に補償するために、支払われる保険金額を決定することが重要である。

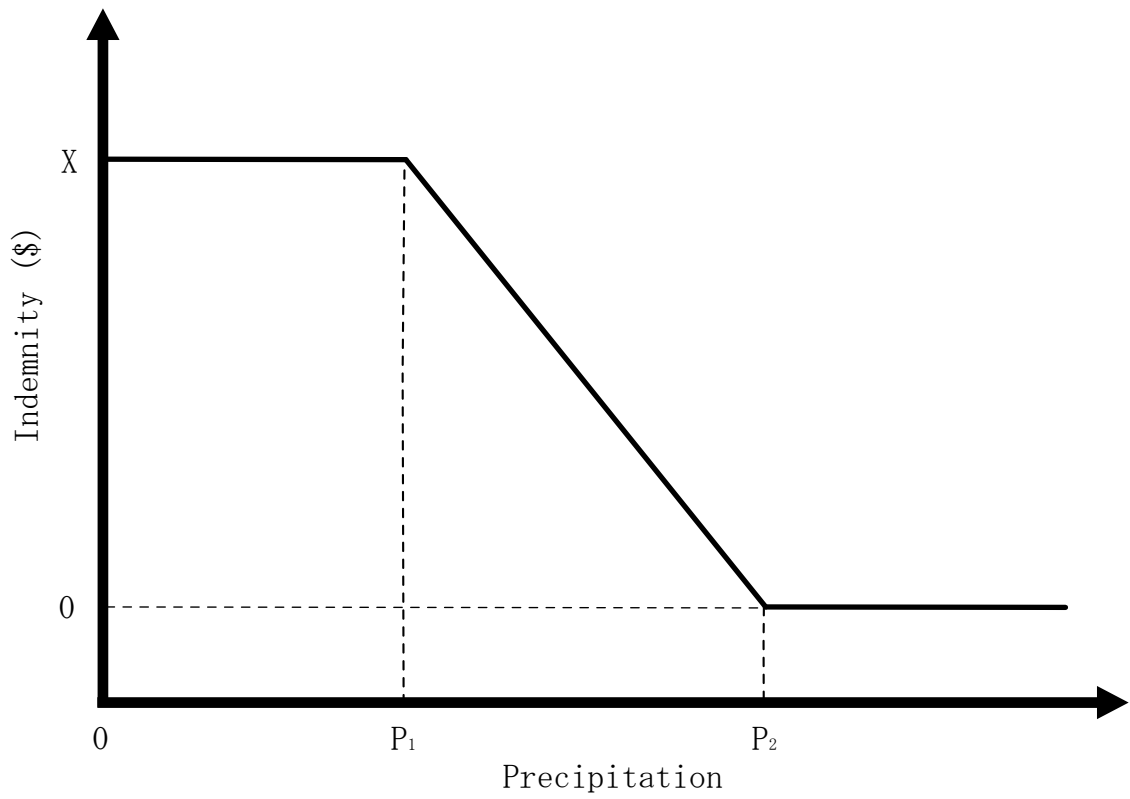


図 3.1 降水量をインデックスとした天候インデックス保険

3.2 本研究の天候インデックス保険

3.2.1 本研究で設計した天候インデックス

本研究では、第2章で行った気象データの分析を元に天候インデックスを簡易的に開発する。図2.17では、7月中の標準化した気温がコーンベルトを中心に強い負の相関関係がみられたため、天候インデックスとして採用する。式(3.1)に天候インデックス保険の保険金を示す。

$$I = \begin{cases} 0 & (T < 1) \\ (T - 1) \times y_b \times p_e \times l & (1 < T < 2) \\ y_b \times p_e \times l & (T > 2) \end{cases} \quad (3.1)$$

I は天候インデックス保険で支払われる保険金、 T は天候インデックスで標準化した気温、 y_b は基準単収で郡における過去4年の平均単収、 y_e は栽培前の予測価格(全米一律)、 l は被保険者である農家が設定する保証水準となっている。 l は一律に80%とした。本研究で適用した天候インデックスは、CRUによる7月の平均気温を標準化であり、郡レベルの空間分解能を持っている。保証範囲は標準化気温が1から2までとなっており、平年と比較して高温になった事象が保証対象となっている。また、図3.2に上記で算出する天候インデックス保険をグラフにしたものを示す。

3.2.2 天候インデックス保険の評価

本研究で設計した天候インデックス保険を評価するため、天候リスクにともなって減少する農家の収入を保証することができたかを評価する。評価方法は、以下の式(3.2)と(3.3)を計算し、農家が得られる利益を推計する。

$$r = y_x \times p_m - c \quad (3.2)$$

$$p = r + I \quad (3.3)$$

r はUSDAの郡レベルのトウモロコシ単収 y_x と収穫時トウモロコシ価格 p_m の乗算から栽培コスト c を差し引いた営業利益である。 p は営業利益 r に保険金 I を加算した利益である。栽培コストと収穫時の価格は、USDA ERSより取得したHeartland地方における統計データを用いた¹。図A.2に過去の内訳の金額を示す。赤字であった営業利益が保険の補償金が支払われたことで黒字に転換したかを確認し、本研究の天候インデックス保険の補償能力を評価する。

¹<http://www.ers.usda.gov/data-products/commodity-costs-and-returns.aspx>




図 3.2 標準化した気温をインデックスとした天候インデックス保険

3.2.3 2008 年から 2013 年の天候インデックス保険の結果

以下に本研究で算出した、2008 年から 2013 年までの郡レベルの営業利益、天候インデックス保険による保険金および郡レベルの利益の結果を示す。

2008 年の結果

2008 年は、コーンベルト周辺地において標準化された気温が 1 を超えることがなく、天候インデックス保険の保険金支払いのトリガーが発生することはなかった。図 3.3 は、農家が得られたと推定される営業利益である。コーンベルト周辺では、0 から 400 ドルの営業利益となる結果になった。しかし、多数の郡で営業利益はマイナスとなる結果となった。図 3.4 は営業利益のヒストグラムである。2008 年は、2008 年から 2013 年の平均（平年）とほぼ同じ分布となった。




図 3.3 郡レベルの営業利益 (2008 年)

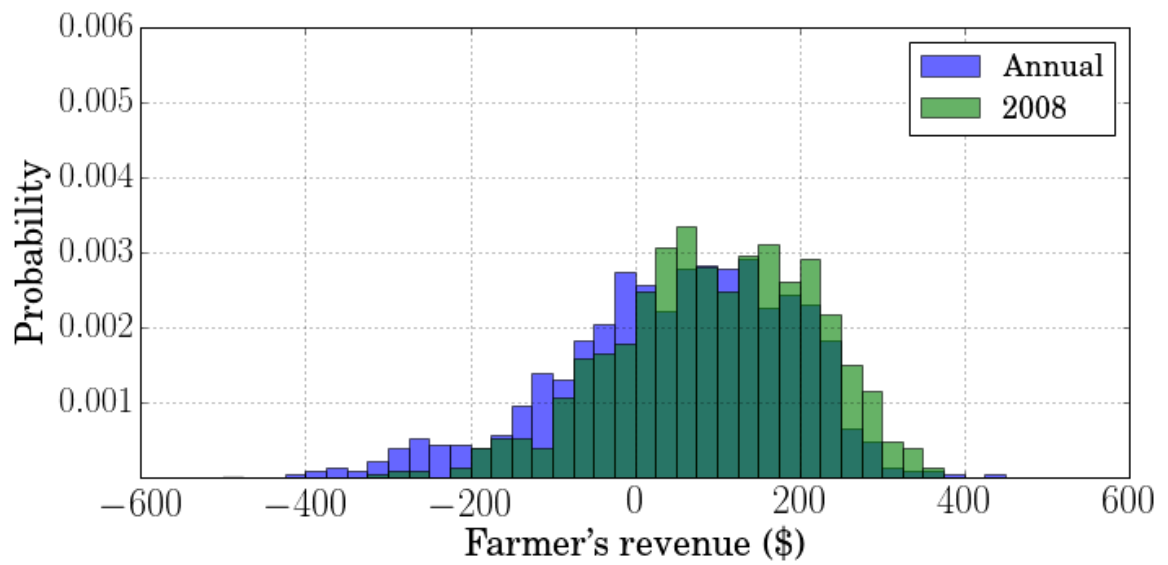


図 3.4 郡レベルの営業利益のヒストグラム (2008 年)

2009 年の結果

2009 年は、2008 年と同様に天候インデックスのトリガーが発生しなかった。図 3.5 では、広範囲で 0 から 200 ドルの営業利益が得られていたことがわかる。また、その周辺の地域で -200 から 0 の損失を被っている地域が存在した。図 3.6 のヒストグラムを確認すると、平年と比較して営業利益が 0 に集中しており、標準偏差が小さい分布となっていた。




図 3.5 郡レベルの営業利益 (2009 年)




図 3.6 郡レベルの営業利益のヒストグラム (2009 年)

2010 の結果

2010 年は、ごく一部の地域で天候インデックス保険による保険金支払いが発生した(図 3.9)。ヒストグラムでも、支払われた保険金は小規模であったことが分かる(図 3.10)。営業利益は、南部などの地域で赤字が発生した(図 3.7)。営業利益のヒストグラムを確認すると、2010 年は平年と同様の分布を示している(図 3.8)。しかし、赤字が発生した地域に対して保険金支払いは発生せず、損失を補填したことにならなかった(図 3.11)。よって、保険金支払い後においても、利益を赤字から黒字へ転換させることができなかった。

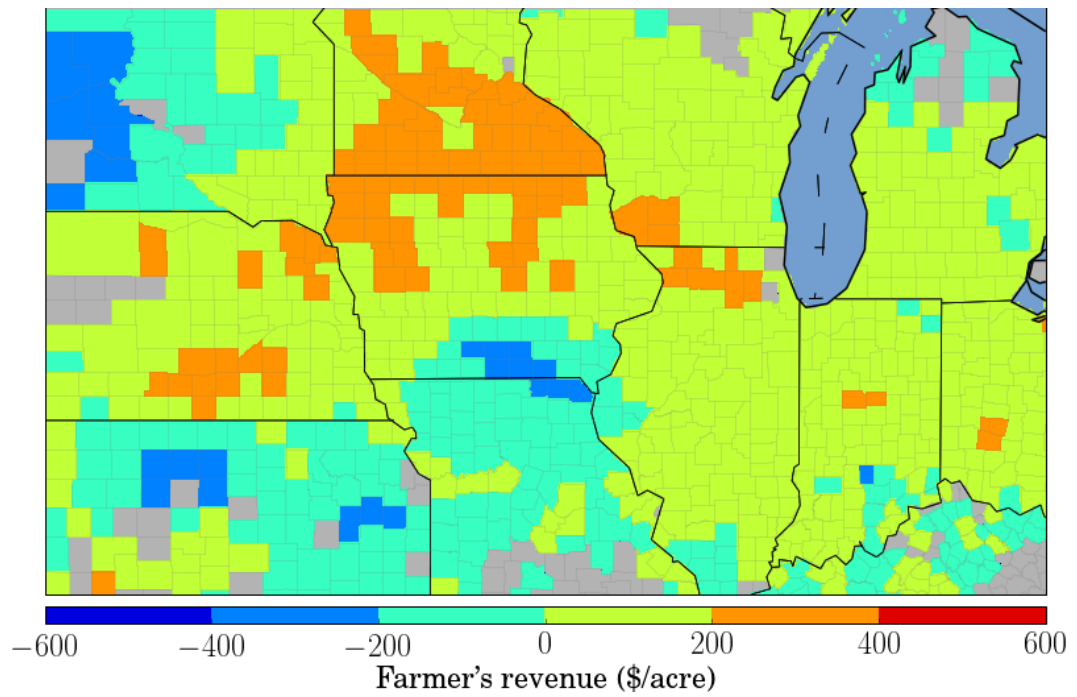


図 3.7 郡レベルの営業利益 (2010 年)




図 3.8 郡レベルの営業利益のヒストグラム (2010 年)

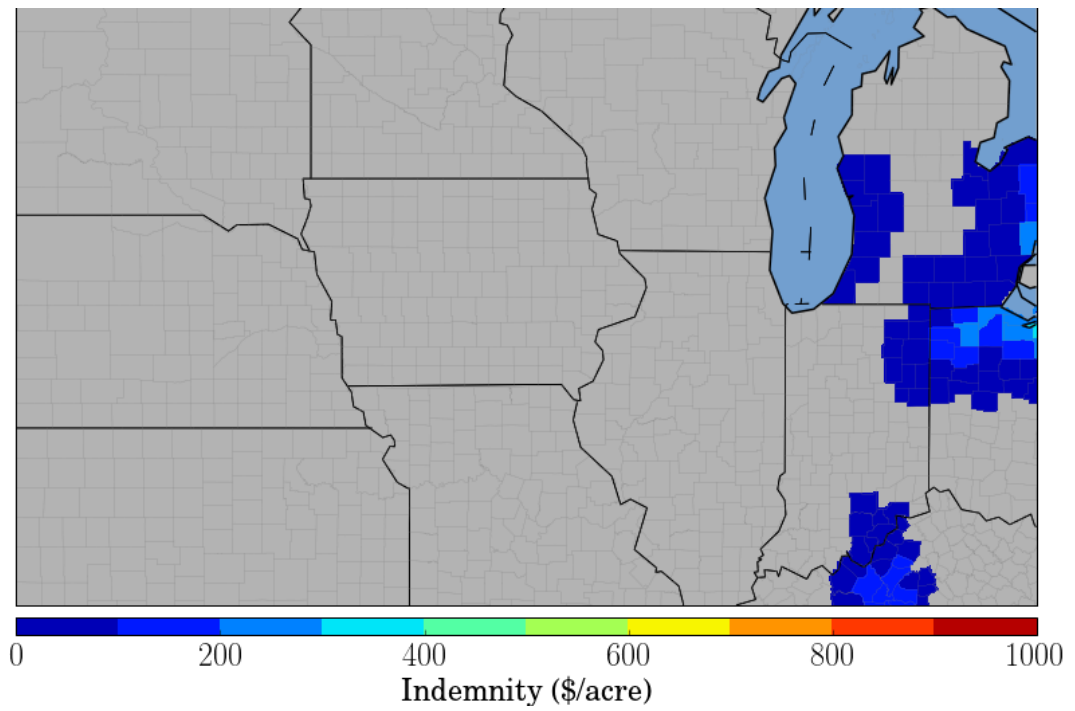


図 3.9 郡レベルの天候インデックスの保険金 (2010 年)




図 3.10 天候インデックス保険の保険金のヒストグラム (2010 年)




図 3.11 郡レベルの利益 (2010 年)




図 3.12 郡レベルの利益のヒストグラム (2010 年)

2011 の結果

2011 年は、営業利益が北部や南部の一部の地域を除き、高い営業利益が得られている（図 3.13, 3.14）。天候インデックス保険は、より広い範囲で適用される算出結果となり、東の地域において、高い保険金が支払われている（図 3.13）。しかし、営業利益で赤字となった地域で適正な保険金が適用されていなかった。よって利益において、赤字から黒字へ転換するといった範囲が確認されなかった（図 3.17, 3.18）。

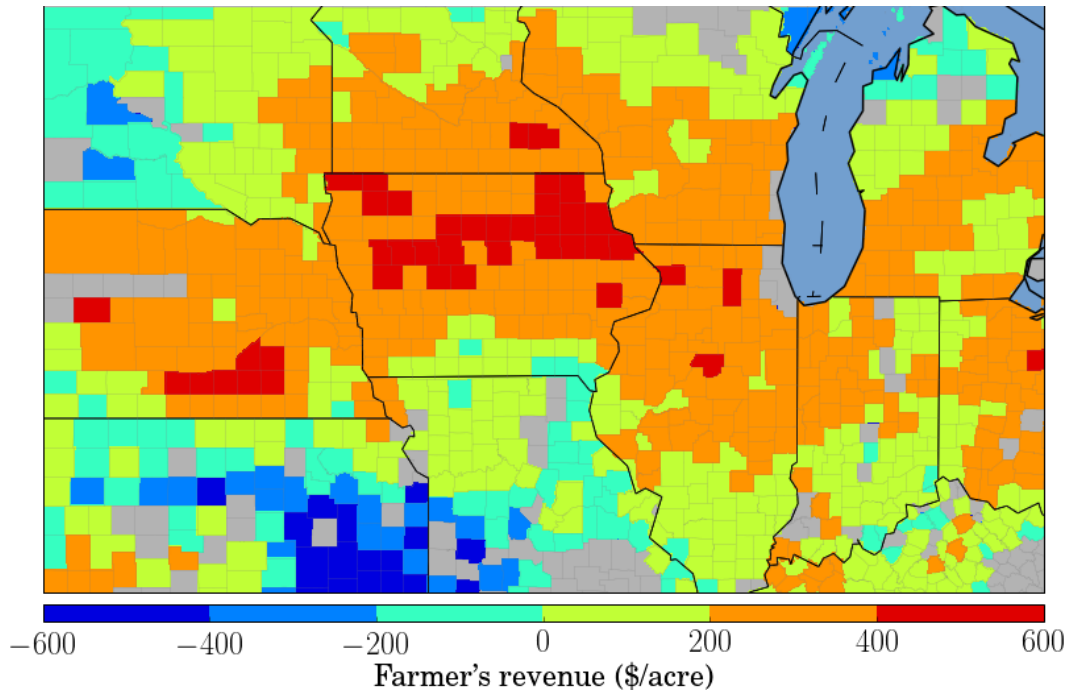


図 3.13 郡レベルの営業利益 (2011 年)




図 3.14 郡レベルの営業利益のヒストグラム (2011 年)




図 3.15 郡レベルの天候インデックスの保険金 (2011 年)




図 3.16 天候インデックス保険の保険金のヒストグラム (2011 年)




図 3.17 郡レベルの利益 (2011 年)




図 3.18 郡レベルの利益のヒストグラム (2011 年)

2012 の結果

2012 年は歴史的な大干ばつの年であった。よって、南部の地域などで 200 ドルを超える営業利益の大きな損失が発生した（図 3.19）。図 3.20 のヒストグラムにおいて、幅が広い分布が示されており、営業利益の格差が大きいことが分かる。保険金は、例年よりも高い支払い金額が発生しており、特にインディアナ州、イリノイ州、アイオワ州、ネブラスカ州のコーンベルトの中心地域で顕著にみられる（図 3.21, 3.22）。天候インデックスを適用することで、大きな損失を被っていた南部の地域において、赤字から黒字へ転換できたことが確認できた（図 3.23）。しかし、高い営業利益を得られた地域において、高額な保険金支払いが発生していたため、大きな利益の格差が生じる結果となった。

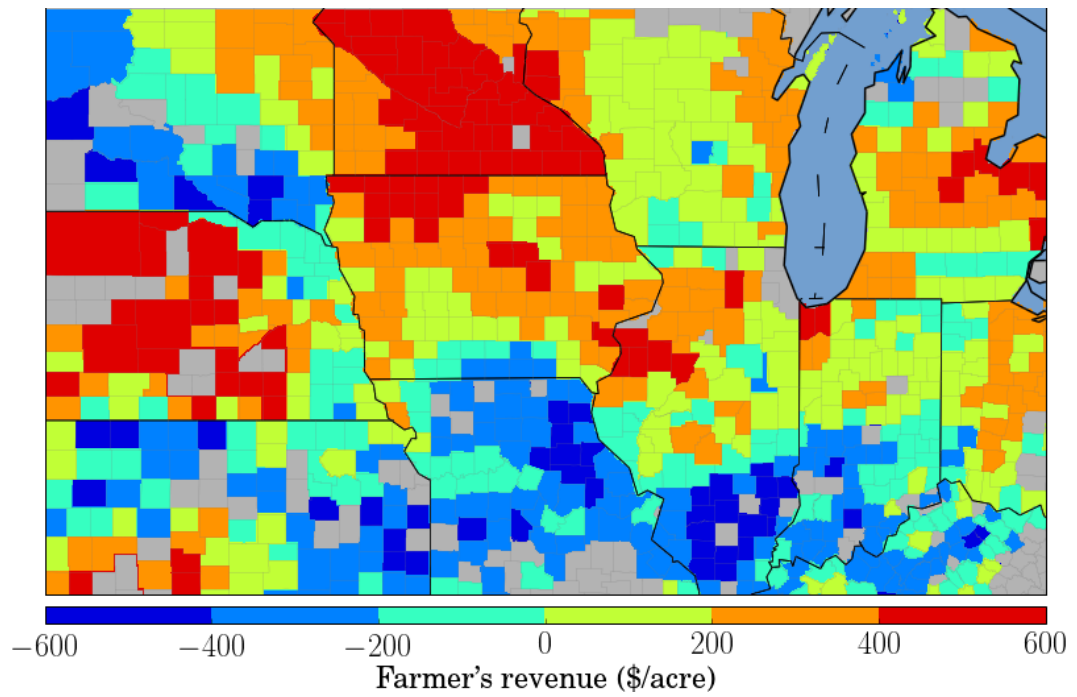


図 3.19 郡レベルの営業利益 (2012 年)




図 3.20 郡レベルの営業利益のヒストグラム (2012 年)




図 3.21 郡レベルの天候インデックスの保険金 (2012 年)




図 3.22 天候インデックス保険の保険金のヒストグラム (2012 年)




図 3.23 郡レベルの利益 (2012 年)




図 3.24 郡レベルの利益のヒストグラム (2012 年)

2013 年の結果

2013 年は、南部や北部の地域で営業利益の損失を被る地域が確認された（図 3.25）。また、図 3.26 のヒストグラムでは、平年と同様の分布を示しているが、営業利益の最大金額が低いことが分かる。天候インデックス保険は、トリガーが発生せず、営業利益で損失を被った地域に対して補償されることはなかった。




図 3.25 郡レベルの営業利益 (2013 年)




図 3.26 郡レベルの営業利益のヒストグラム (2013 年)

3.3 天候インデックス保険の考察

本研究では、7月のCRUの最大気温を用いた天候インデックス保険を設計し、2008年から2013年のコーンベルト周辺における営業利益損失の補償状況を確認した。結果、2008、2009、2013年において保険金支払いが発生せず、広い範囲で赤字が発生した。また、2010年、2011年、2013年では、保険金の支払いが発生したにも関わらず、赤字から黒字へ転換させることはなかった。2012年では、深刻な干ばつが広範囲で発生したため、平年と比較し高額な保険金支払いが適用されたため、広い範囲で損失を補償することが可能となった。しかし、高い営業利益が得られた地域において、より高い保険金が支払われることになったため、利益の格差が生じる結果となった。

本研究の天候インデックス保険では、農家の営業利益の損失を適正な形で補償することができなかったため、ベースリスクが存在していることが分かる。CRUの最大気温は標準化することでトウモロコシ作況指数とおよそ -0.7 の相関係数がコーンベルト一帯の地域で確認できた。しかし、インデックスとトウモロコシ単収とは完璧な相関が得られなかったため、適正な保険による補償が実行されなかった。また、アメリカはトウモロコシ価格の変動性が非常に高いため、気候災害が発生しなくても、価格の下落によって損失を被る場合が考えられる。天候インデックス保険では、このような価格リスクによる利益損失の補填が困難であることが考えられる。

天候インデックス保険は、干ばつや洪水など単体のリスクを保証する保険であり、多種多様なリスクから農家の利益を保証することは困難である。気候災害リスクだけではなく、価格リスクなど様々なリスクに対して農家の利益を保証するためには、作物収入保険の適用が有効であると考えられる。作物収入保険は、価格リスクの保証を可能とするが、実際のトウモロコシ単収を推定する必要がある。しかし、従来の作物収入保険では、査定に要するコストが高くなってしまい、広く普及させることは難しい。よって、複数の気候データや衛星によるトウモロコシの生育データを活用した単収推定手法が有効であると考えられる。

第4章 衛星データと深層学習による単収推定モデルの開発

4.1 既存手法と本研究による作物単収推定

4.1.1 作物生長モデルによる単収推定

作物生長モデルは、農業プロセスの意思決定支援として、1970年代から開発されるようになった。作物生産における生理学プロセスをモデル化することで、作物の日々の生長をシミュレーションすることが可能となった。作物生長、病虫害発生、農業気象など幅広い分野のモデル開発が進められ、統合的に扱うアプリケーションが数多く開発された。多くのモデルでは、作物の光合成によるバイオマス生成を Monteith (1972) の植物による光利用効率を利用した日射量を乾燥バイオマスに変換するモデルが基盤となっている。

EPIC (Erosion Productivity Impact Calculator) は数多くある作物生長モデル中で初期に開発された代表的なものである (Williams, Jones & Dyke, 1984)。もともとアメリカにおける土壌及び水の評価を目的として、USDA のモデリングチームによって開発された。最初の主要アプリケーションは、土壌浸食を計算するものであった。その後、次々と機能が拡張され、温室効果ガス排出に対応するアルゴリズムなど農業活動に関わるあらゆる環境評価に用いられている。

その他の主要な作物生長モデルとして、DSSAT (Decision Support System for Agrotechnology Transfer) が挙げられる。DSSAT は、複数の作物生長モデルが統合され、穀物やジャガイモ、豆類など数多くの作物生長をシミュレーションすることができる (Jones *et al.*, 2003)。シミュレーションには、栽培開始から収穫までの日別気象データと層ごとの土壌データが入力データとして必要になる。気象データは、最低気温、最大気温、日射量、降水量となっており、一日でも欠損するとモデルは動作しない。さらに播種日、播種間隔、灌漑管理、施肥など多くの栽培管理パラメータと作物品種の特徴を表す品種パラメータを与える必要がある。

DSSAT をはじめとする作物生長モデルを活用するには、栽培管理パラメータと品種パラメータをキャリブレーションする必要がある。高い精度で作物収量を推定するためには、詳細な情報を必要とするため、農業試験場でのシミュレーションに適していた。そこで、衛星データを活用したデータ同化手法によるシミュレーション手法が開発された。まず最初のキャリブレーションは、品種パラメータである。品種パラメータを先に固定することで、農地でのあらゆる環境条件下でのシミュレーションが可能となる。キャリブレーションには、農業試験場などで詳細に記録される栽培データを活用する。気象データ、土壌データ、栽培管理パラメータは与え

られる情報とし、品種パラメータをランダムに変えて、収量を計算する。試験場の単収と比較し、尤もらしい品種パラメータの組み合わせを選択する。パラメータの決定には最尤法が用いられることがある。次に現地の状況に合わせるため、栽培管理パラメータをキャリブレーションする。農業試験場の場合、栽培管理は事細かに記録されているが、現地の農地では、播種、灌漑や施肥などのスケジュールを正確に把握することは困難である。そこで、衛星データを利用したデータ同化手法が提案された。作物生長モデルは、光合成による日射量の乾燥バイオマスへの転換量を計算する過程で、葉面積指数（LAI：Leaf Area Index）を算出している。LAIとは、単位面積上方に植物の葉を敷きつめた際に占める面積の割合を示し、放射伝達モデルを駆使することで、衛星データから求めることが可能となっている。衛星から推定したLAIを観測値とし、作物モデルが算出するLAIが観測値と同化するように栽培管理パラメータを最適にする。最適な栽培管理パラメータの組み合わせは、評価関数を用いて選択する。注意する点として、放射伝達モデルを用いて衛星データから作物のLAIを推定する場合、放射伝達モデルのパラメータキャリブレーションも必要になるため、地上データはある程度必要となる。図4.1に作物生長モデルによる収量推定の全体の流れを示す。

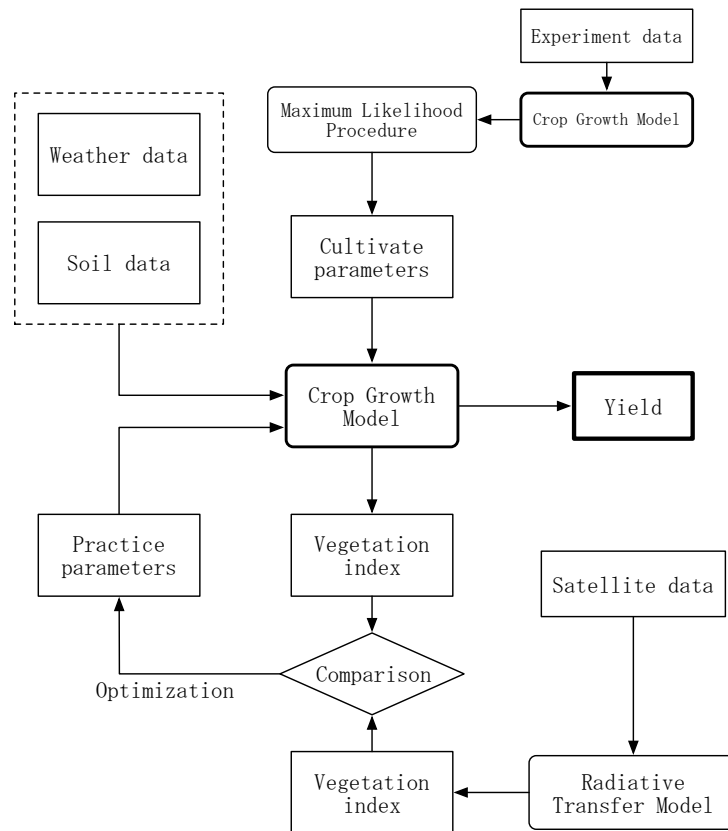


図 4.1 衛星データによる作物生長モデルのデータ同化手法

4.1.2 衛星データと機械学習による単収推定

機械学習は多種多様な分野で活用されており、作物単収の推定にも利用されている。作物生長モデルは、植物生理学など研究者の過去の研究成果に基づき、単収推定するためのメカニズムが設計されている。作物生長はあらゆる環境によって影響を受けるため、人の手で単収推定に有効な特徴量を作成することは多大な労力を要する。それに対し、機械学習では環境データから収量に関連する特徴量がアルゴリズムによって自動的に抽出される。

機械学習には、大量のデータを処理する必要があるため、大きな計算コストを要していたが、近年のコンピューター性能の向上により、マシンリソースの障壁は小さくなりつつある。アルゴリズムも様々なものが提案されており、目的の事象を高い精度で推定することができるようになったので、注目を集めている。衛星データと機械学習を用いた作物収量推定の研究成果は数多く報告されている。

衛星データを用いたニューラルネットワークによる作物収量推定

Jiang *et al.* (2004) は、衛星による NDVI, APAR (Absorbed Photosynthetically Active Radiation), 樹冠表面温度, 水ストレス指数と単位面積あたり平均収量を入力データとし、冬小麦の収量を推定した。対象地は中国河南省の 30 の郡となっており、1999 年の郡レベルの収量を推定している。この研究では、5 つの入力データを衛星から取得して、推定モデルを学習している。30 の郡のうち、20 を学習用、10 を評価用に用いており、ANN と重回帰による推定精度を比較している。ANN による誤差はおよそ 3.5% で重回帰は 11.6% と ANN は統計的手法より高精度な結果が得られている。しかし、対象期間は 1 年で対象地域は 1 省となっている。ニューラルネットワークはモデルの表現力が高いため、訓練データに含まれない未知のデータに関しては、でたらめな結果を出力する可能性がある。この問題を過学習 (Overfitting) という。機械学習において過学習は、重要な課題であり、改善する方法はいくつか存在する。その一つとして、データ量を増やし、あらゆる事象を学習時にモデルに与えるという方法が挙げられる。

多時期衛星データを用いた重回帰とニューラルネットワークによる作物収量推定

Li *et al.* (2007) は、MODIS と AVHRR (Advanced Very High Resolution Radiometer) から算出した NDVI を用いて、イリノイ州を中心としたアメリカ中西部と Great Plains 地方のトウモロコシと大豆の収量を推定した。推定には Artificial Neural Network (ANN) が用いられ、重回帰モデル (MLR: Multivariate Linear Regression) による推定方法と比較されている。MODIS は 2000 年から 2004 年までの 16 日間コンポジットの 1km 空間分解能が用いられている。MODIS は 5 年分のデータしか用いられていないので、機械学習の学習データとしては十分でない。データ量を補うため、1982 年から 2004 年までの 22 年間の AVHRR のデータが用いられた。AVHRR のコンポジット期間は半月である。衛星データは 5 月 10 日から 10 月 31 日

までの生育期間に観測されたものが用いられている。収量は郡レベルで推定されており、州によって異なるが相関係数 0.8 以上の推定精度が得られている。

4.1.3 作物生長モデルと機械学習による手法の比較

4.1.1 と 4.1.2 でそれぞれ述べた作物生長モデルと機械学習による単収推定手法の特徴を表 4.1 でまとめた。

データの可用性は、単収推定モデルを構築する際に要するデータの入手可能度で優劣を評価した。作物生長モデルは、動作させるために固定された気象データが日別で必ず必要となる。気象データは地上観測ステーションによって観測されるが、設置数はまばらであり、ベースリスクの原因となる。特に途上国では、ステーションの数が十分とはいえない。図 4.2 に NOAA の Global Historical Climatology Network (GHCND) が管理する世界中の気象観測ステーションの分布密度をカーネル密度推定で表した。ステーションの設置数が地域によって大きく偏りがあることがわかる。機械学習は、衛星から取得される環境データを入力データとして利用できるため、作物生長モデルと比較するとデータの可用性が高いと考えられる。

農業保険を考慮した作物単収推定モデルを扱う場合、モデルの適用可能範囲が重要となる。適用可能範囲が拡大することで、局所的な天候不順や災害に対し、リスク分散の効果が得られ、保険会社にとって支払いリスクの軽減につながる。推定範囲が拡大した場合、栽培する作物の品種も多様になる可能性がある。作物生長モデルの場合、各品種によってパラメタのキャリブレーションが必要となり、広い範囲での適用は困難になる。

適用期間も適用範囲と同様、推定する期間が長くなると技術改善や品種改良が進む。作物生長モデルの場合、パラメタのキャリブレーションやモデルのアルゴリズム修正が必要となる。機械学習は取得するデータに応じて学習を行い、モデルを構築するため、作物生長モデルよりも適用性は高いと考えられる。

作物生長モデルの利点として、収量以外の作物をとりまく土壌や水環境をシミュレーションできるということが挙げられる。DSSAT は、作物の生長以外に蒸発散量、水や土壌ストレスや二酸化炭素の濃度による影響といった様々な環境条件をシミュレーションに考慮することができる。機械学習では、入力データと出力データの関係をモデリングするため、データに含まれていない作物をとりまく環境プロセスをシミュレーションすることは難しい。

機械学習では学習に多大な計算コストを要する。特にニューラルネットワークは、学習時のパラメタ更新において GPU (Graphics Processing Unit) による並列処理必要になる。ニューラルネットワークモデルの規模にもよるが、一般に購入できる GPU 搭載のパソコンであれば、処理は可能であため、さほど大きな障壁とはいえない。

以上より、作物生長モデルは導入時にデータによる制約を強く受ける。均一なデータを長期間かつ広範囲に整備することは困難である。ベースリスクを低減し、かつ途上国でも導入可能な作物収量推定モデルを構築するためには、機械学習が有用であると考えられる。

表 4.1 推定手法の比較

	データの 可用性	適用 可能範囲	適用 可能期間	環境 評価	マシン リソース
作物生長モデルによる収量推定				✓	✓
機械学習による収量推定	✓	✓	✓		

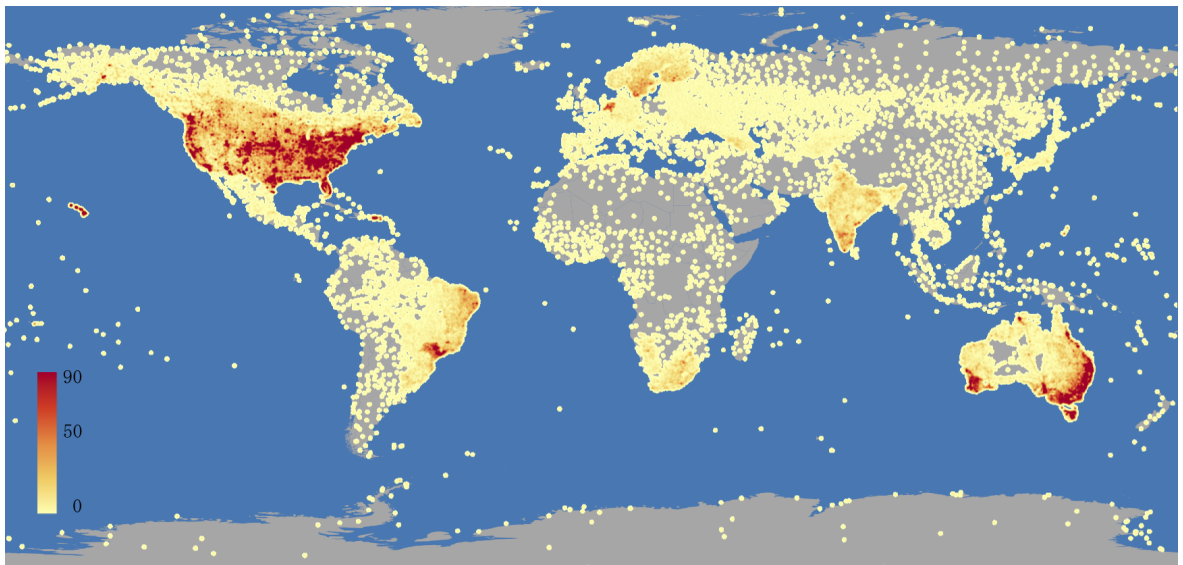


図 4.2 GHCND の気象観測ステーションの分布密度

4.2 機械学習によるトウモロコシ単収推定

本研究では、機械学習で郡レベルのトウモロコシ収量を推定するため、気象データと衛星データから算出した植生指数を入力データとして用いた。図 4.3 に機械学習による収量推定モデルを評価するまでの流れを示す。気象データは、NASA が配布する 1 km グリッドデータ、Daymet を用いる。衛星データは、Terra/MODIS の陸域プロダクト MOD09A1 から植生指数 EVI を算出し、雲によるノイズを Wavelet 変換によってスムージングする。Daymet と EVI は日別の時系列データである。別途、5 日間積算のデータセットを用意し、日別と 5 日間積算の集計期間が異なる 2 つのデータセットをそれぞれ正規化を行った。そして、作物栽培地が詳細に分類された土地被覆データ CDL より、トウモロコシ畑上でマスキングし、トウモロコシ収量を推定するためのモデルを機械学習した。学習する際、全てのデータセットの 8 割を学習用に利用し、残りの 2 割を推定精度の評価用とした。推定期間は 2008 年から 2013 年までとし、全米を対象

とした。

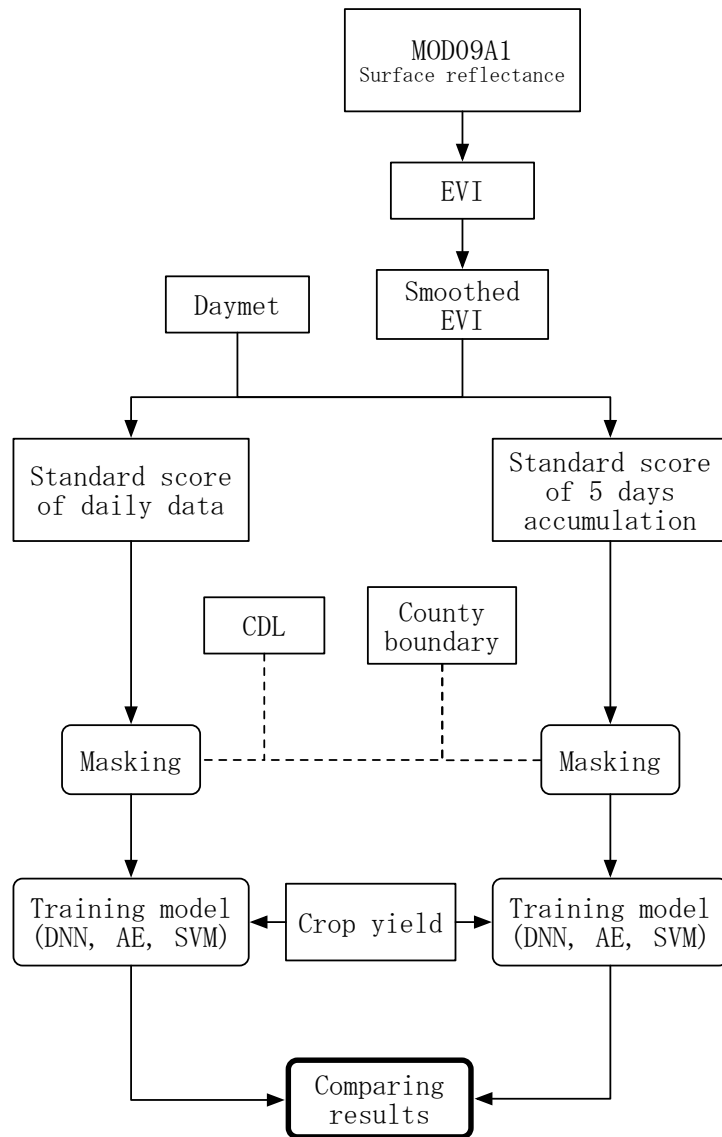


図 4.3 本研究の機械学習のデータ処理の流れ

4.2.1 本研究で利用した機械学習アルゴリズム

本研究では、Support Vector Machine (SVM)、ニューラルネットワークを利用した Deep Neural Network (DNN) と Autoencoder の複数の機械学習アルゴリズムを利用し、収量推定モデルを学習し、それぞれの推定精度を比較した。DNN のような多層のニューラルネット

ワークの構造を用いた機械学習を深層学習とよぶ。

Deep Neural Network

本研究で利用する DNN は、フィードフォワード型の隠れ層 6 層のニューラルネットワークである。図 4.4 にその概念図を示す。ニューラルネットワークの最初の層は入力層となっており、各期間の気象データと衛星の EVI が入力される。日別のデータセットの場合、通日の気象データと EVI の 365 日分が入力層の各ニューロンに入力される。5 日間積算の場合、73 期間のデータが入力される。最後の層は出力層になっており、郡レベルのトウモロコシ単収を出力する。各隠れ層は、4000 個のニューロンで構成されている。

ニューロンとは神経細胞のことであり、人工ニューラルネットワーク (Artificial Neural Network : ANN) は脳のニューラルネットワークの働きをモデルにしている。ニューロンは神経回路網に多数存在し、お互いは無数のシナプスによって繋がっている。ニューロン間の信号伝達は、それをとりまくニューロンからの入力信号が加わり、電位変化が発生し、ニューロンが興奮した場合に他のニューロンへの入力信号となる。これを「発火」という。発火することで、次のニューロンへ信号が伝わり、ネットワークが形成される。フィードフォワード型の ANN は、複数のニューロンで構成されるネットワーク層が多層に積み重なることで、複雑なモデルを表現することができるといわれている。ANN のニューロンのモデルを図 4.5 に示す。入力 x が n 個あるとき、それに対応する重み w も n 個存在することになる。細胞内電位 s が閾値 θ を越えるとき、発火条件を満たして出力 y が 1 となる。閾値以下の場合には、出力は 0 となる。各ニューロンには、活性化関数 f を持ち、式 (4.2) で表されるシグモイド関数が用いられてきた。本研究では、式 (4.3) の Rectified Linear Unit (ReLU) を採用した。

$$s = \sum_{n=1}^N w_n x_n \quad (4.1)$$

$$f(s) = \frac{1}{1 + e^{-as}} \quad (4.2)$$

$$y = f(s) = \max(0, s) \quad (4.3)$$

入力データを DNN に入力することで、トウモロコシ収量を推定できるわけだが、パラメータである重み w を最適なものに更新する必要がある。訓練前の最初の w は、ランダムで与えることになる。DNN の出力層が出力した y と訓練データ d との誤差ができるだけ小さくなるように w を出力層に近い層から更新していく。この学習方法を誤差逆伝播法 (Backpropagation) という。誤差を評価には、誤差関数を利用する。トウモロコシ単収は連続値であるため、回帰問題として扱うことになる。回帰問題では、誤差関数に平均二乗誤差 (MSE: Mean Square Error) を利用する。

4.2. 機械学習によるトムロコシ単収推定

ニューラルネットワークの学習は、与えられた評価関数を最適にするパラメータを求める最適化問題として扱われている。最適化の手法は数多く提案されており、本研究では Kingma & Ba (2014) が提案する Adam (adaptive moment estimation) を用いた。




図 4.4 本研究の DNN の概念図

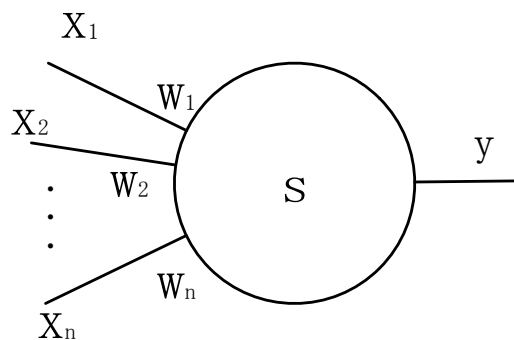


図 4.5 ニューロンのモデル

Autoencoder

ニューラルネットワークを用いた次元圧縮のアルゴリズムとして、Autoencoderがある。Autoencoderの概念図を4.6に示す。Autoencoderは、入力層、中間層と出力層を持つ構造となっている。中間層は入力層よりも小さい次元（ニューロンの数）となっており、出力層は入力層と同じ大きさの次元を持っている。Autoencoderは、入力層を出力層で再現するように中間層を最適化する。これを事前学習とよび、事前学習の結果を用いることで、特徴抽出部分の大半のパラメータを最適に近い値で学習を始めることが可能となっている。

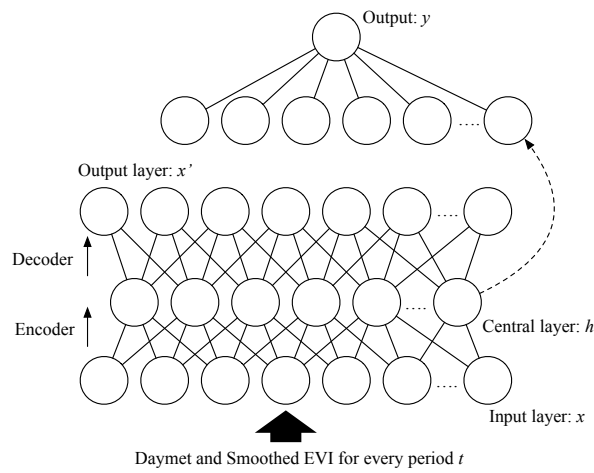


図 4.6 Autoencoder の概念図

Support Vector Machine

SVMはVapnik (1995)によって提唱された機械学習アルゴリズムである。ニューラルネットワークの学習方法である逆誤差伝播法は、汎化能力があまり高くないという欠点があった。SVMは、この欠点を改善するために、マージン最大化という最適化手法を適用した単純パーセプトロン型の線型識別手法である。汎化能力とは、学習時には存在しなかった入力パターンが与えられた際、学習済みのデータの中から何らかの法則性・規則性を見つけ出し、未学習のパターンにそれを適用し、正しい出力を得るというものである。これは過学習を対処するためにも重要な点である。単純パーセプトロンとは、入力層、中間層、出力層の3層構造を持つモデルで、ニューラルネットワークモデルの原型ともいえる。単純パーセプトロンは、線形分離可能なシンプルな問題にしか対応ができなかったが、カーネルトリックという非線型写像を用いることで線形分離不可能な問題でも対応が可能となった。本研究では、サポートベクターマシンを応用したサポートベクトル回帰 (Support Vector Regression) を用いて、トムロコシ

単収推定モデルを学習した。そして、他のニューラルネットワークモデルと併せて推定精度を評価することで、機械学習手法の有用性について考察する。

4.2.2 単収推定のための学習方法

単収推定では、2008年から2013年までのアメリカの郡レベルのデータを用いる。これは、CDLが全米で整備されているのが2008年からである。全データの8割を機械学習の訓練用に使用し、残りをモデルの評価用として用いる cross validation を適用した。気象データと衛星のEVIを入力データを x 、ターゲットを出力 d としたとき、ペアの (x, d) をサンプルとする。機械学習では、 x を与えることで、 y を出力する。 d は望ましい出力となり、 y が d に最も近くなるようにモデルを訓練する必要がある。これが機械学習のアイデアである。

4.3 単収推定で利用したデータ

4.3.1 北米高解像度気象データ Daymet

第2章では、長期再解析データ ERA-Interim と CRU の全球気象データセットを用いて、作況指数との相関分析を行ったが、空間分解能は 1.5° と 0.5° となっており、本研究の課題であるベシスリスクの低減には、粗いデータであった。機械学習による収量推定では、NASA が配布している気象メッシュデータ、Daymet を入力データとして用いる (Thornton *et al.*, 2014)。Daymet は、最低気温、最大気温、降水量、湿度、日射量、積雪水量の日別データが 1 km で用意されている。対象範囲は北米のみとなっている。

4.3.2 衛星植生指数 EVI

作物の生育情報を機械学習による推定モデルに入力するため、衛星データから植生指数 Enhanced Vegetation Index (EVI) を算出した。本研究で用いた衛星データは、Terra 衛星に搭載された Moderate Resolution Imaging Spectroradiometer (MODIS) の陸域プロダクト MOD09A1 である。MOD09A1 は、8日間コンポジットの大気補正済みの地表面反射率となっており、雲や大気による影響を極力取り除いたデータとなっている。The Land Processes Distributed Active Archive Center (LP DAAC ¹) より無償でダウンロードすることができる。森林や作物の植生モニタリングを衛星データでモニタリングする際、衛星データから算出する正規化植生指数 (NDVI: Normalized Difference Vegetation Index) が用いられてきた。NDVI は、衛星のマルチスペクトルセンサーの赤バンドと近赤外バンドで観測された反射率を式 (4.4) より求める。

$$\text{NDVI} = \frac{\rho_{\text{NIR}} - \rho_{\text{red}}}{\rho_{\text{NIR}} + \rho_{\text{red}}} \quad (4.4)$$

¹<https://lpdaac.usgs.gov/>

ρ_{red} は赤色に相当する MODIS バンド 1 (620 - 670 nm), ρ_{NIR} は近赤外に相当する MODIS バンド 2 (841 - 876 nm) となっている。近赤外域は植物によく反射され、赤色域はクロロフィルがよく吸収する特徴を活かし、2つのバンドで観測された反射率を正規化したものが NDVI である。値は-1 から 1 にかけて分布し、1 に近いほど植生の量や活性度の高さを示す指標として用いられる。

作物には複数の生育ステージがあり、衛星から観測される NDVI の値も変化する。トウモロコシの場合、播種 (Planting), タッセリング (Tasseling), シルキング (Silking), 受粉 (Pollination), ミルクステージ (Milk stage), ドウステージ (Dough stage), デントステージ (Dent stage), 成熟期 (Mature), 収穫期 (Harvest) と生育ステージがある。この様に植物の季節的におこる自然界の動植物が示す諸現象の時間的変化を植物季節 (Phenology) という。アメリカでは、トウモロコシを 4月から5月にかけて播種し、9月から11月に収穫を行う。衛星でトウモロコシ畑を観測した際、NDVI は播種してからシルキングにかけて上昇し、ピークを迎える。デントステージの間でなだらかに下り、収穫までに NDVI 値が急に下がるというプロファイリングを示す。継続的に観測される衛星データから NDVI の変化を捉えることで、対象植生の生育状況をモニタリングする。

NDVI を用いて作物モニタリングを行った研究は多くあるが、EVI を推奨する手法が報告されている。EVI は赤色域と近赤外域に加え、青色域の反射率を加えている。大気や土壌の影響を受けにくく、バイオマス密度の高い植生に対する感度が NDVI よりも良いとされ、作物モニタリングに適していると考えられている (Galford *et al.*, 2008; Wardlow, Egbert & Kastens, 2007)。EVI の算出方法は、式 (4.5) である。

$$\text{EVI} = G \times \frac{\rho_{\text{NIR}} - \rho_{\text{red}}}{\rho_{\text{NIR}} + C_1 \times \rho_{\text{red}} - C_2 \times \rho_{\text{blue}} + L} \quad (4.5)$$

ρ_{blue} は青色に相当する MODIS バンド 3 (459 - 479 nm) となっている。 G はゲイン調パラメータで 2.5, C_1 は赤色域帯域補正パラメータで 6, C_2 は青色大気補正パラメータで 7.5, L は群落背景の輝度補正パラメータで 1 となっている。

一般的に NDVI は EVI よりも高く推移し、植生が濃い範囲では、NDVI 値は飽和する場合がある。大気による影響に対し、EVI は NDVI よりも強いとされ、トウモロコシの植物季節を捉える指標として有効であると考えられる。

4.3.3 植生指数 EVI のノイズ除去

雲がある時に算出された植生指数 EVI は、値が極端に下がる。継時的に取得された EVI は、ノイズを含むデータとなり、作物の生育状況を正確に把握することが困難になる。Sakamoto *et al.* (2005) では、Wavelet 変換によって雲ノイズを EVI から除去することで、水稻のフェノロジー観測を実施し、水稻の生育ステージの精緻な把握が可能となった。

本研究では、Wavelet 縮退を応用した Hard thresholding 法 (Donoho, 1995) を用いて、MODIS データから算出した EVI から雲の影響を取り除き、スムージング処理を施した。Wavelet 縮

退は、複数回の Wavelet 変換を用いる多重解像度解析による非線形のノイズ除去処理方法であり、データ圧縮やノイズ除去などで活用されている (Aggarwal & Rathore, 2011)。対象となる信号の統計的性質が未知の場合でも有効な方法として知られている (Donoho, 1995)。Hard thresholding 法は、以下の手順で行う。

1. 原信号 (EVI) を Wavelet 変換することで Wavelet 展開係数を計算する
2. Wavelet 展開係数の絶対値が閾値より小さかった場合、係数を 0 に置き換える
3. Wavelet 展開係数を逆 Wavelet 変換によって信号に再構成する

Wavelet 変換は式 (4.6) で行う。

$$Wf(x) = \int_{-\infty}^{+\infty} f(x) \frac{1}{\sqrt{a}} \psi\left(\frac{a-b}{a}\right) dx \quad (4.6)$$

ψ は Wavelet 母関数、 a はスケーリング関数、 b はシフティング係数となっている。母関数は、Sakamoto *et al.* (2005) を参考にし、Coifet 2 を選択した。Wavelet 変換を行う回数は式 (4.7) で求める。

$$level = \text{Floor}(\log n) \quad (4.7)$$

Floor は実数の少数部分を切り捨てて整数にする床関数、 n は信号長である。Hard thresholding 法の閾値は式 (4.8) で算出する。

$$\lambda = \sigma \sqrt{2 \log n} \quad (4.8)$$

$$\sigma = \frac{MAD}{0.6475} \quad (4.9)$$

σ はノイズの分散、 MAD は Media Absolute Deviation (中央絶対偏差) である。図 4.7 は、トウモロコシ畑の EVI と Hard thresholding 法でスムージングした EVI を示している。Wavelet 縮退を適用することで、雲によって極端に低下した EVI のスムージングが可能となった。本研究では、MOD09A1 を 2001 年から 2013 年までアメリカ本土の範囲で取得し、EVI を算出してから Wavelet 変換によるスムージング処理を行った。図 4.8 に 2008 年 7 月 18 日の EVI の処理結果を示す。




図 4.7 MODIS EVI と Wavelet 変換でスムージングした EVI




図 4.8 Wavelet 変換でスムージングした北米の EVI (2008 年 7 月 18 日)

4.3.4 入力データの正規化

ニューラルネットワークの入力側から特徴量を上手く抽出し、出力側に伝搬するためには、データの前処理を行う必要がある。例えば、欠損値の内挿が挙げられるが、正規化は重要な処理といえる。正規化 (normalize) とは、異なるスケールのデータを一定の基準にしたがって変形し利用しやすくすることである。

本研究で用いるデータは、気温、降水量、日射量や EVI など、それぞれの単位は °C, mm, W/m² となっており、データが持つレンジは異なる (EVI は無次元である)。よって、単位が異なるデータを機械学習に直接用いても、学習が上手く行われな可能性が強いため、データの正規化が必要となる。本研究では、式 (4.10) を計算し、Standard score による正規化を行った。

$$X'(t) = \frac{X(t) - \mu_t}{\sigma_t} \quad (4.10)$$

$X(t)$ は期間 t におけるデータ値、 μ_t は期間 t における平均値、 σ_t は期間 t における標準偏差である。本研究では、日別と 5 日間積算の二つの入力データセットを用意し、各データセットで訓練した機械学習の推定モデルを評価する。日別の t は通日、5 日間積算は積算期間の期数である。Standard score は、データを平均が 0 で分散が 1 のデータに変換する操作となっており、天候不順を考慮したデータ整形になると考えられる。

4.3.5 土地被覆データによる入力データのマスキング

本研究の単収推定モデルで利用する入力データの空間分解能は、気象データ Daymet が 1 km、衛星の EVI が 500 m となっており、郡レベルのトウモロコシ単収の空間分解能よりも高い。郡単位で入力データを集計し、機械学習で学習させると、トウモロコシ畑以外の情報が混入する恐れがある。トウモロコシ畑の情報を抽出するため、USDA が公開している土地被覆データ Cropland Data Layer (CDL) を用いた (United States Department of Agriculture, USDA)。CDL は 100 種類以上の栽培作物の農地が分類されており、森林や都市、水域などの土地被覆分類も詳細に行われている。空間分解能は 30 m から 56 m となっており、Landsat5, 7 やインドの衛星 RESOURCESAT-1 (IRS-P6) の観測データを用いて作成されている。2008 年からアメリカ本土全域で整備されており、毎年、更新して無料配布されている。図 4.9 は、2008 年の CDL である。

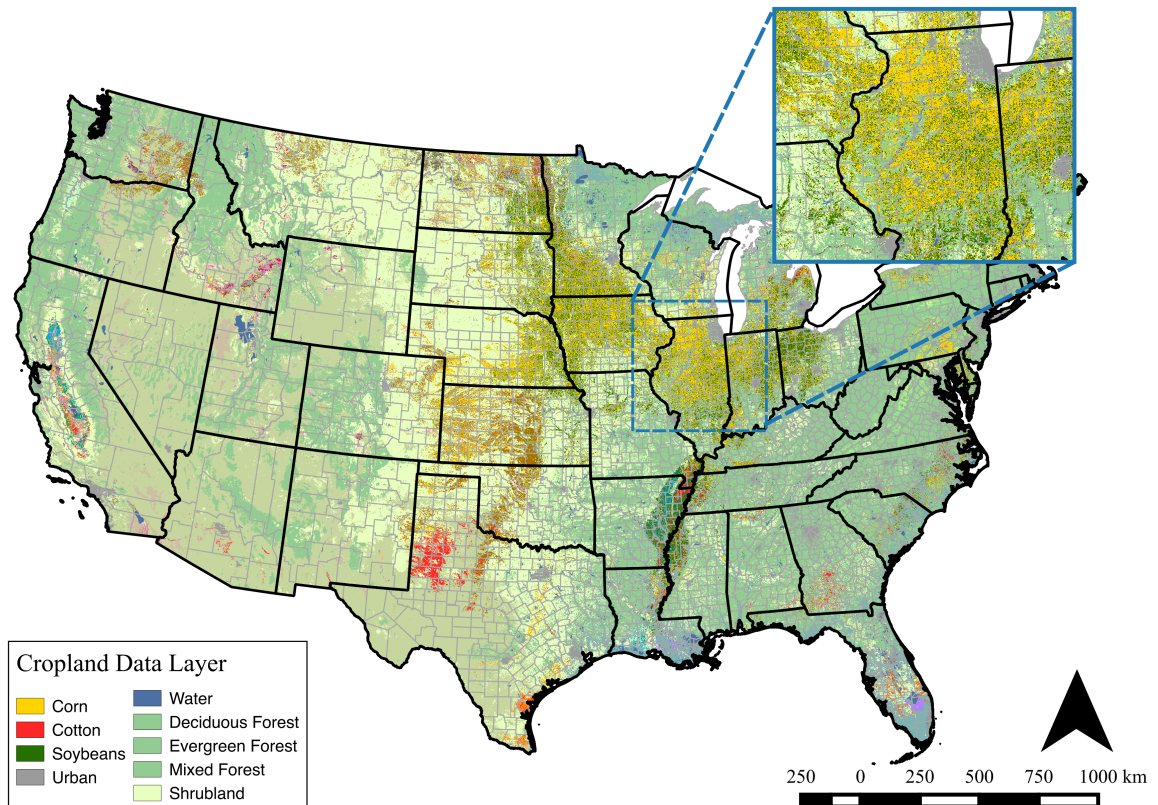


図 4.9 2008 年の CDL

4.3.6 収量推定精度の評価

本研究では、気象データと EVI の日別データと 5 日間積算データの 2 種類の入力データセットを用意し、3 つの機械学習アルゴリズムでトウモロコシ単収推定モデルを学習させた。よって、本研究では、六つの手法で郡レベルのトウモロコシの単収を推定する。それぞれの推定精度を評価するため、平均二乗誤差 (RMSE: Root Mean Square Error) と決定係数 (R^2) を求め、比較した。RMSE は式 (4.11)、 R^2 は式 (4.12) で計算する。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.11)$$

$$R^2 \equiv 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4.12)$$

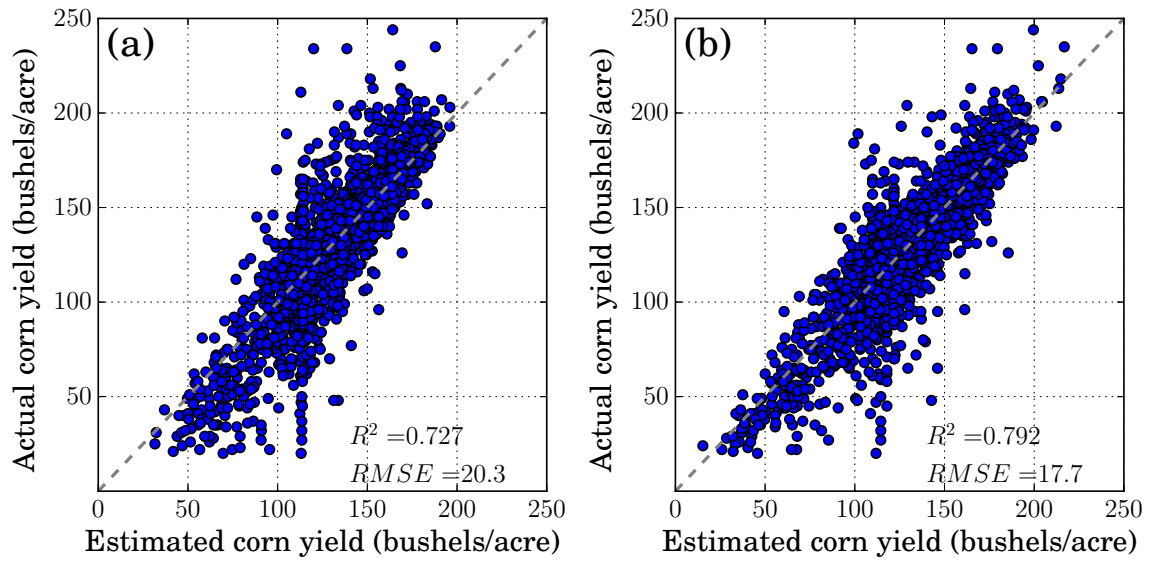
N はテスト用のデータサンプル数、 y はテスト用データのトウモロコシ収量 (観測値)、 \bar{y} はテスト用トウモロコシ収量の平均、 \hat{y} は推定結果である。

4.4 単収推定の結果

単収推定の結果を表 4.2 に示す。最も精度の高かった方法は、SVM に 5 日間積算データを入力した場合であった。しかし、日別データを入力した場合、精度が低下した。Autoencoder では、5 日間積算データより日別データで学習した方が高い精度が得られた。DNN の場合、どちらの入力データセットでも高い精度で郡レベルのトウモロコシ収量を推定することができた。図 4.10, 4.11, 4.12 に推定結果の散布図を示す。

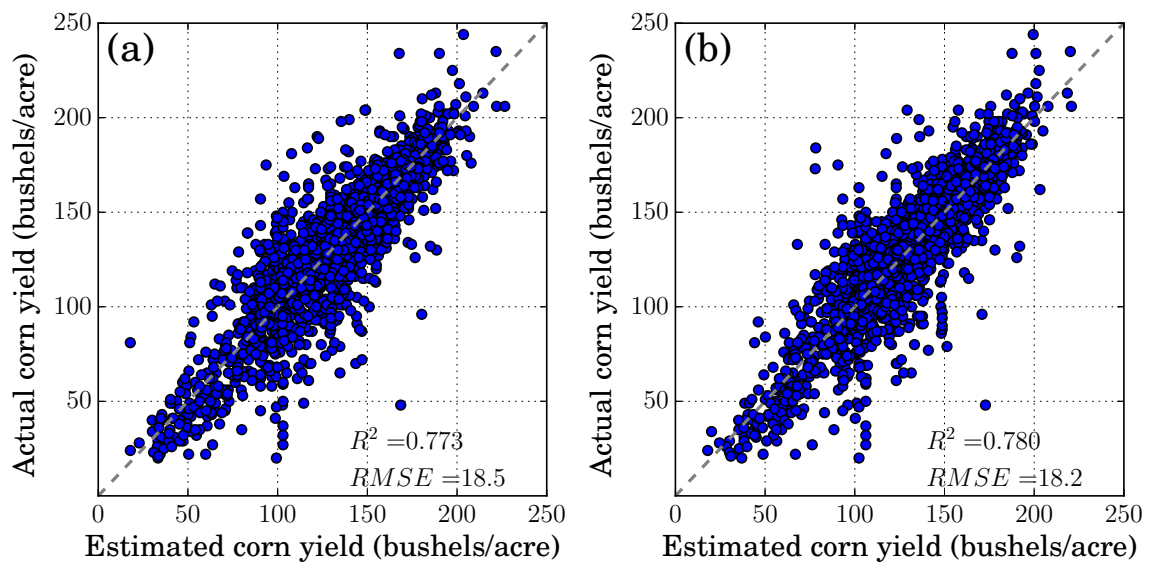
表 4.2 Estimation results with several models

	Daily input dataset		5-day accumulation dataset	
	RMSE	R^2	RMSE	R^2
SVM	20.4	0.727	17.7	0.792
DNN (six hidden layers)	18.5	0.773	18.2	0.780
Autoencoder	19.0	0.759	21.3	0.700



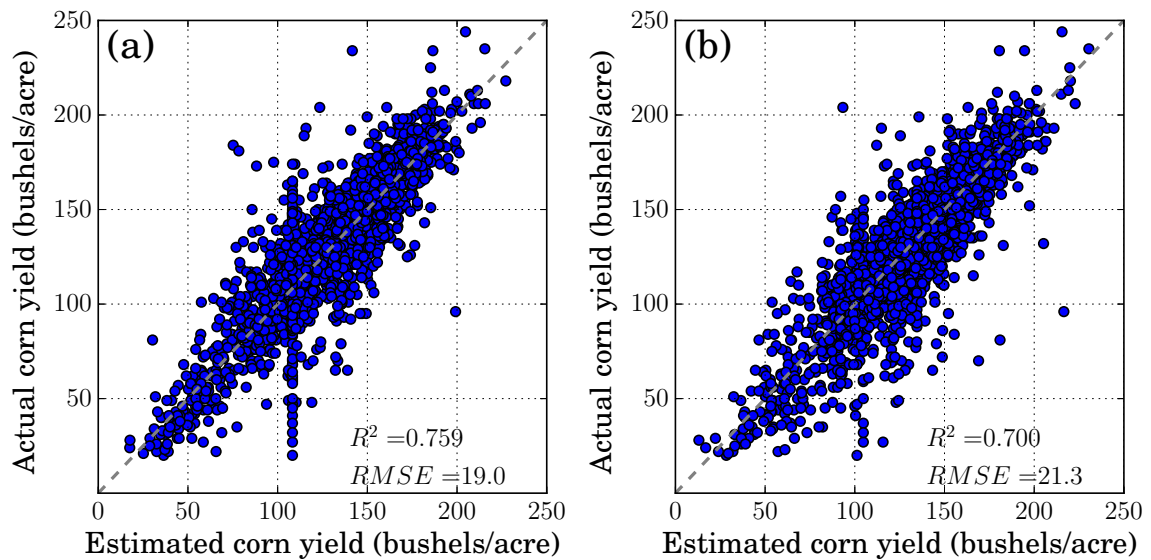
(a) 日別入力データセット, (b) 5日間積算入力データセット

図 4.10 SVM によるトウモロコシ単収推定



(a) 日別入力データセット, (b) 5日間積算入力データセット

図 4.11 DNN によるトウモロコシ単収推定



(a) 日別入力データセット, (b) 5日間積算入力データセット

図 4.12 Autoencoder によるトウモロコシ単収推定

4.5 推定結果の考察

機械学習を用いて、アメリカ全土で栽培されるトウモロコシ単収を2008年から2013年の期間で推定することができた。本実験では、6つの方法で単収推定を行い、推定精度を比較した。5日間積算の気象データとEVIをSVMに入力する方法で最も高い精度が得られたが、高次元の日別データを入力すると推定精度が低下した。図4.10を確認すると、低収量と高収量のサンプルにおいて、過大推定と過少推定がそれぞれみられた。逆にAutoencoderは推定精度が上昇し、DNNは大差がなかった。ニューラルネットワークは、高次元の入力データから特徴量をうまく抽出できたことが考えられる。より高精度な手法を開発する際、気象データや植生情報以外に土壌、品種、農家情報などを入力データセットに加える可能性があり、ますます高い次元となる。その場合、DNNやAutoencoderの有効性はより高くなると考えられる。

散布図4.10, 4.11, 4.12において、教師データに大きく異なる推定結果がいくつかみられる。これらの結果は、CDLが示すトウモロコシ畑が郡の面積に対して極めて小規模な場合であった。つまり、気象データとEVIをまばらな少数のCDLのピクセルでマスキングをおこなったため、トウモロコシ畑におけるデータの空間代表性が希薄してしまったことが、推定精度の低下の原因になったと考えられる。よって、地理空間データを用いた収量推定を行う場合、ある程度の規模を持つ耕作地帯の必要がある。

第5章 深層学習による単収推定モデルの性能評価について

5.1 第5章の目的

本章では、DNN を利用した深層学習による単収推定モデル学習の性能を評価した。第4章で、深層学習による単収推定モデルの学習方法について示し、全米のトウモロコシ単収を郡単位で高精度に推定した。しかし、深層学習の単収推定に関する研究はまだ多くないため、どのようなデータ整備状況で十分な推定精度が得られるか検証がなされていない。本研究では、「適用範囲の限定」、「汎化性の評価」、「衛星データの有効性」の3つの観点で深層学習のモデル学習の性能を検証した。

第4章では、全米で単一の単収推定モデルを学習した。アメリカでは南北でおよそ2000 km 以上にもわたってトウモロコシが栽培されている。よって、それぞれの気候帯で、異なる品種のトウモロコシを栽培や栽培法を適用している可能性が強い。本研究の深層学習による単収推定モデルでは、気候データと衛星から推定したEVIを入力データとしているため、品種に関する情報が特徴量に含まれていない。また、灌漑や施肥に関する情報も同様である。品種や栽培環境の差異による生産性を推定モデルに考慮させるためには、品種と栽培情報を深層学習に与える必要があるが、詳細な品種と栽培の情報は現在公開されていない。そこで、学習データセットに適用する範囲を全米ではなく、トウモロコシの主要生産地へと限定することで、品種や栽培環境の差異がトウモロコシ単収に与える影響を小さくさせることを試みた。評価方法は、トウモロコシ主要産地の学習データセットで学習させた単収推定モデルの推定精度が、全米の場合と比較して精度が向上したかを確認した。評価用データセットもトウモロコシ主要産地のみとした。

汎化性 (generalization) とは、機械学習で学習したモデルが未知のデータに対して正しい出力をする能力である。機械学習は、学習用データから何かしらの法則性・規則性を見つけ出し、学習モデルの推定結果と推定対象の誤差を最小化することを目的としている。そのため、学習データに含まれていない事象について、誤差が最小化されるとは限らない。学習用データによって高い推定精度が得られたが、評価用のデータに対して大きい誤差が生じてしまう状態のことを過学習 (overfitting) という。第4章では、2006年から2013年までの全米データの8割から無作為に抽出したデータを学習用とし、残りを2割とする cross validation の手法を適用した。作物の収穫具合は天候状況によって大きく左右されるが、天候状況は年によって複雑に異なる。よって、機械学習で単収推定モデルを学習させる際は、未学習のデータセットへの対応

能力である汎化性が非常に重要となる。本研究における深層学習の汎化性を評価するため、学習用データセットと評価用データセットを年によって分別した。分別方法は、2009年から2013年までのデータを学習用データセットとして単収推定モデルを学習し、2008年のデータセットを評価用データセットとした。このような分別を2008年から2013年までそれぞれ適用し、評価用データセットによる推定精度を確認した。この様にある年もしくはサイトのデータを学習用には一切使用せず、評価用で利用する評価方法を、leave-one-out cross validation (LOOCV) という。

既往研究による、機械学習の作物単収推定手法では、衛星による植生指数や気候データなどが与えられている。衛星の植生指数は、作物の生育状況を把握する上で重要な情報とされているが、機械学習の推定精度にどれほど寄与するか確認されることはなかった。本研究では、MODISで推定したトウモロコシのEVIが、トウモロコシ単収の推定精度にどれほど寄与するか検証するため、EVIだけを入力データセットで単収推定モデルを学習した場合とEVIを入力データセットから外した場合で、推定精度を比較した。

5.2 推定精度向上のための対象範囲の限定

5.2.1 Heartland 地方のみのデータ利用

USDA では、アメリカの農業生産の特徴を考慮した 9 つの地域分類が定義されている（図 5.1）。なかでも Heartland 地方は、コーンベルト地帯であるアメリカの中西部に位置しており、トウモロコシの主要産地といえる。CDL でトウモロコシ畑を確認すると、地域によって栽培環境が異なることが分かる。図 5.2 は、Illinois 州 Kankakee 郡周辺、Kansas 州 Stafford 郡と Washington 州 Benton 郡周辺の耕作地帯を示す。Heartland 地方に属する Illinois 州周辺では、農地が区画で分けられていることが分かる。トウモロコシ畑の中に大豆畑が点在しており、トウモロコシの主要産地であることが分かる。一方、Kansas 州 Stafford 郡や Washington 州 Benton 郡では、円形のトウモロコシ畑が確認できる。これはピボット灌漑といわれており、地下から汲み上げた水をパイプを回転させながら作物に水を供給する。この様なピボット灌漑が行われている郡の平均単収は高く、栽培環境は大きく異なると考えられる。5.2 では、灌漑などの栽培環境が類似していると考えられる Heartland 地方のトウモロコシ単収推定を行い、単収推定の精度向上が達成されるか検証する。検証方法は、cross validation を適用した。

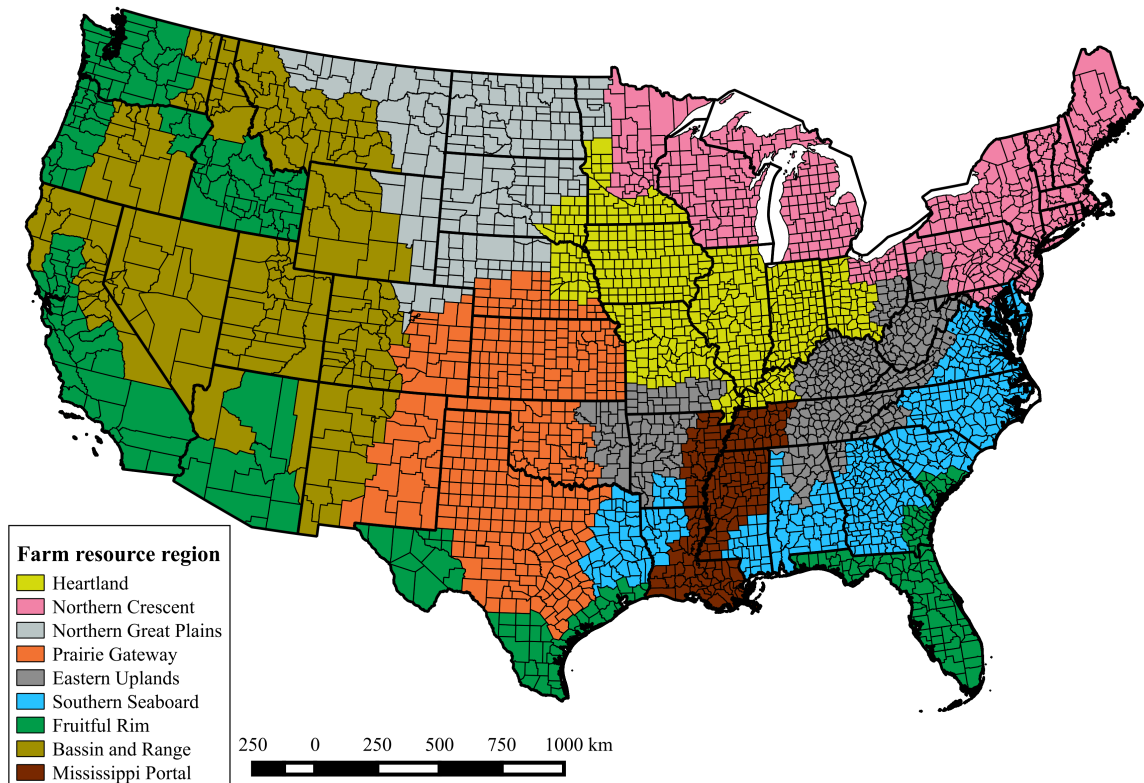


図 5.1 Farm resource region




図 5.2 Illinois 州 Kankakee 郡周辺の耕作地帯（左）Kansas 州 Stafford 郡周辺の耕作地帯（中）Washington 州 Benton 郡周辺の耕作地帯（右）

5.2.2 Heartland 地方のトウモロコシ単収の推定結果

図 5.3 は、Heartland 地方のみのデータを DNN によって単収推定モデルを学習した推定結果である。推定精度は、 $R^2 = 0.89$, RMSE=11.55 (bushels/acre) となっており、全米の場合、推定精度は $R^2 = 0.78$, RMSE=18.2 (bushels/acre) であるため、対象範囲をトウモロコシ主要産地に限定することで、推定精度の向上が確認された。




図 5.3 Heartland 地方のみのデータで学習した DNN によるトウモロコシ単収の推定結果

5.3 深層学習の汎化性の評価

5.3.1 既往研究の汎化性評価について

Jiang *et al.* (2004) では、1999 年の河南省における市単位の冬小麦単収をニューラルネットワークで推定した。入力データセットは、NDVI, APAR (absorbed photosynthetically active radiation), 林冠表面温度, 水ストレス指数, 10 年平均単収が適用されている。NDVI, APAR, 林冠表面温度および水ストレス指数は NOAA AVHRR の観測データから算出した NDVI を用いて, APAR や水ストレス指数を推定している。林間表面温度も NOAA AVHRR より推定されている。単収推定精度は、30 市の中, 20 市を学習用に適用し残り 10 市を評価用に利用した。単年のデータのみで学習している上, 利用しているサンプルデータが全部で 30 と非常に少なく, 過学習の問題が懸念される。

Drummond *et al.* (2003) では、複数の土壌データ (pH, 土壌有機物, 標高など) や気象データ (気温や降水量) を用いて, メッシュのトウモロコシと大豆の単収推定モデルをニューラルネットワークで学習させた。この研究では, 過学習を評価するため, あらゆる条件で実験を行った。3 つの試験地で 1993 年から 1997 年までの 10 通りのデータが用いられており, それぞれメッシュデータとなっている。サンプルの総数はおよそ 3000 となっている。全サンプル数を 5-fold cross-validation¹ や LOOCV で評価することで, ニューラルネットワークによる過学習を検証した。5-fold cross-validation の場合, 土壌データや 6 つの気象データを入力データセットに加えることで, トウモロコシと大豆の単収との強い関係が得られた。LOO の場合, 推定精度が著しく低下し, 強い過学習の傾向がみられた。気象データを 1 つに絞ることで, 推定精度が少なからず改善したが, 依然として過学習の問題が残った。

5.3.2 本研究の汎化性評価

本研究では, LOOCV によって深層学習による単収推定モデルの汎化性について評価した。第 4 章では, 2008 年から 2013 年の全米のトウモロコシ単収推定モデルを SVM, DNN, autoencoder で学習を行い, cross validation による推定精度の評価を行った。Cross validation では, 全期間かつ全地域のデータを網羅的に学習データセットに取り込むことが可能なので, 学習したモデルは多様な事象に対して対応が可能であると期待できる。しかし, 未知の事象に対して適正な推定が可能か定かではない。例えば, 2008 年から 2013 年のデータで推定したモデルが 2014 年の単収が推定可能か明らかではない。本研究で開発した単収推定モデルは農業保険に適用するため, あらゆる天候事象に対応させ, 想定外となる事象を可能な限り排除する必要がある。そこで, LOOCV によって, 5 年分の学習用データセットで学習した単収推定モデルが, 学習用データセットに含まれていない年のデータに適正な単収推定が可能か確認した。また, 対象範囲をトウモロコシ主要産地である Heartland 地方のみを適用することで, 品種や栽培環境の

¹データセットを 5 つに分割し, その内の 1 つを評価用として利用し, 残る 4 つを学習用として用いる。そして, 4 つに分割されたデータセットをそれぞれ評価用として 4 回検証を行い, 4 回の結果を平均して 1 つの推定を得る。

差異による影響の低減を試みた。ニューラルネットワークの構造は、5日間積算データを入力層とする autoencoder に1層の全結合フィードフォワード型のニューラルネットワークを繋げたものとした。

5.3.3 深層学習による単収推定モデルの汎化性評価の結果

LOOCVによるトウモロコシの単収推定結果を図5.4に示す。LOOCVの結果は、2008年から2013年までの各年を学習用データセットから取り除き、5年分のデータで学習させた単収推定モデルをそれぞれの年のデータで評価したものになる。通常の cross validation の結果(図4.10から4.12)と比較し、推定精度は極端に低下したことから、Drummond *et al.* (2003)と同様の結果が得られた。特に歴史的な干ばつが発生した2012年は、 $RMSE=74.792$ (bushels/acre)と最も精度が低い結果となった。

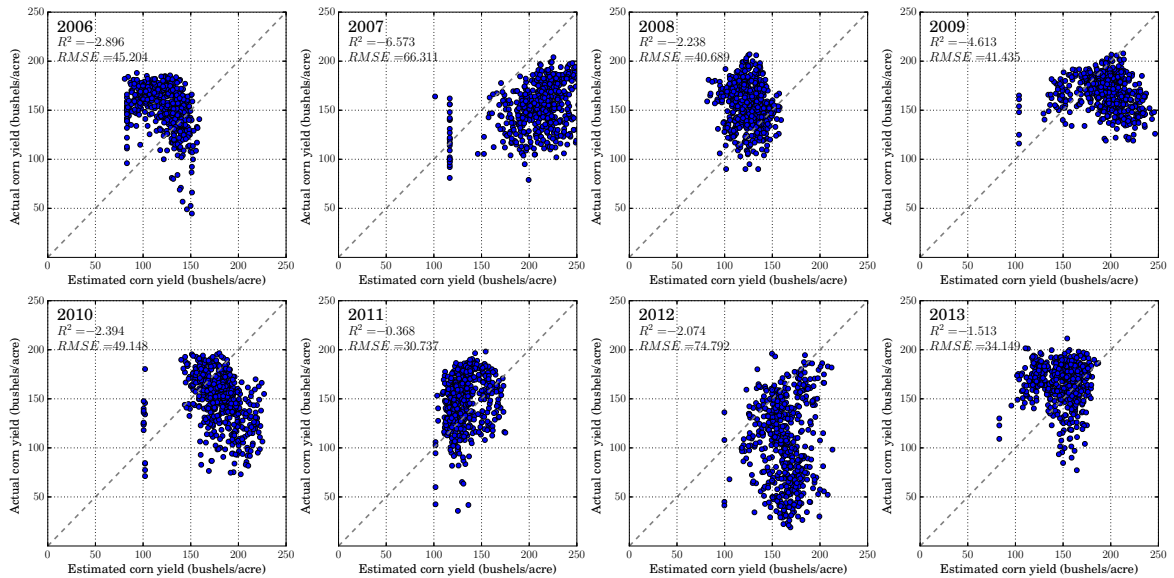


図 5.4 LOOCV によるトウモロコシ単収推定の結果

5.4 EVI が深層学習の推定精度に与える影響の評価

5.4.1 EVI の評価実験の方法

本研究の深層学習によるトムロコシ単収推定モデルには、MODIS から推定した植生指数 EVI が入力データとして利用されている。衛星データを機械学習による単収推定モデルに適用した研究事例は、Jiang *et al.* (2004) や Li *et al.* (2007) で報告されているが、衛星データが単収推定の精度向上にどれ程寄与したか検証は成されていない。よって本研究では、DNN で学習したトムロコシ単収推定モデルの推定精度に、Wavelet EVI がどれほど影響を与えるか確認した。確認方法は、入力データから Wavelet EVI を取り除いて学習した場合と Wavelet EVI だけで推定モデルを学習した場合で決定係数 R^2 を算出した。

5.4.2 EVI 評価実験の結果

EVI を取り除いた場合は $R^2 = 0.75$ となり、気象データと EVI で学習した推定精度の $R^2 = 0.78$ より推定精度が低下した。EVI だけで推定した場合、 $R^2 = 0.59$ となり、Wavelet EVI だけの推定は困難であることがわかった。

5.5 考察

5.5.1 対象範囲限定による精度向上の考察

深層学習で学習する範囲を Heartland 地方に限定することで、単収推定の精度向上が確認された。範囲を限定することで、トムロコシの単収に影響を与えると考えられる特徴量、品種や栽培環境などのばらつきが軽減され、単一のモデルでも高い精度の推定が可能となったことが考えられる。しかし、対象地域を限定しすぎると、得られるデータのサンプル数が十分に得られず、深層学習による単収推定モデルの学習が不十分となる可能性がある。

5.5.2 汎化性に関する考察

LOOCVによって、時間軸方向での汎化性について評価した。2008年から2013年までの6年間のデータのうち、各都市を学習用データセットから取り除き、5年分のデータで学習させた単収推定モデルを、検証年のデータで評価したが、結果、有意な推定精度は得られなかった。考えられる原因は、より長期間のデータセットが必要であったことや、入力次元が高次元であったため過学習が起きてしまったことが挙げられる。汎化性を向上させるためには、さらに長期間のデータセットの利用や、入力次元の低次元化やオートエンコーダなどの次元圧縮を適用したニューラルネットワークの改良が考えられる。

5.5.3 EVIが単収推定モデルの精度に与える影響の考察

衛星で推定した植生指数 EVI が深層学習で学習した単収推定モデルの推定精度にどのような影響を与えるか検証した。検証方法は、入力データから EVI を除去して Daymet だけを利用した場合と EVI のみを入力データとした場合で推定精度を比較した。結果、EVI を取り除いて Daymet だけを入力した場合、決定係数 R^2 が 0.02 ほど低下した。さらに EVI のみで学習させた場合は 0.59 となり大幅な精度の低下が確認された。以上より、EVI は、深層学習による気象データとの単収推定モデルの推定精度向上に寄与するが、EVI のみではモデルの学習は困難であることがわかった。EVI は植生の活性度を定量的に示す指標となっているが、EVI のみで作物の子実のバイオマスである収量を推定することは困難であることが考えられる。

第6章 トウモロコシ単収のダウンスケーリング手法の開発

6.1 単収ダウンスケーリングの重要性

本研究は、地理的要因によって起因するベースリスクの軽減を目指す（1.4の表1.2）。第4章で開発した単収推定手法は郡単位である。コーンベルト周辺の郡は、およそ50 km 距離があり、郡内のトウモロコシの生産性は必ずしも均一とは限らないため、ベースリスクが存在すると考えられる。よって、郡レベルよりも詳細にトウモロコシ収量を推定し、ベースリスクを軽減する必要がある。そこで本研究は、郡レベルの収量をダウンスケーリングする手法を開発する。

6.2 既存のダウンスケーリング

ダウンスケーリングは、空間分解能が粗いデータを詳細にする技術であり、気候変動の評価のために全球気候モデルへ盛んに適用されてきた。ダウンスケーリング手法は、「力学的ダウンスケーリング (Dynamical Downscaling)」と「統計的ダウンスケーリング (Statistical Downscaling)」が主に存在する。力学的ダウンスケーリングは、気候モデルの気象データを初期値・境界条件とし、空間分解能の高いモデルシミュレーションによって、より詳細な気象データを得る手法である。統計的ダウンスケーリングは、観測データの局所的な場と気候モデルの大規模な場との統計的な関係を求め、その関係を元に気候モデルの気象データの空間分解能を詳細化する手法である。統計的ダウンスケーリングは力学的にダウンスケーリングと比較し、計算量が少なく簡易的に実装できるというメリットがあるが、観測データがない地域や将来の気象変動予測への適用が難しいとされている。逆に力学的ダウンスケーリングは、多大な計算コストを要するが、将来の気象変動の影響評価の研究が多く行われている。

農業分野の研究では、ダウンスケーリングした気候モデルのデータを作物生長モデルに入力し、地域レベルの作物収量を推定する研究が報告されている。Shin *et al.* (2010) は、El Niño Southern Oscillation (ENSO)-based historical weather data を力学的と統計的ダウンスケーリングを行い20km 分解能の作物収量シミュレーションを行った。トウモロコシやピーナッツを作物生長モデルでシミュレーションし、気象が収量や水ストレスに与える影響を分析した。ダウンスケーリング後の分解能は20 km となっているので、本研究の郡レベルの収量推定に相当する。気候変動モデルのダウンスケーリング手法は、気象条件が作物に与える影響を分析する

ことができるが、農業保険のベースリスクを改善するための単収推定には適用が困難であると考えられる。

6.3 本研究のダウンスケーリングの手法

本研究では、第4章で開発した郡レベルのトウモロコシ単収推定モデルを用いて、ダウンスケーリングを行う。モデルの学習時では、CDLのトウモロコシ畑上でDaymetとEVIのマスキングを行ったが、ダウンスケーリングでは1 km分解能のデータを収量推定モデルに入力し、CDLのトウモロコシ畑上の単収を推定する。

1 km分解能の収量データは公開されていないため、ダウンスケーリングした単収の評価では、1 kmの単収を郡単位で再集計し、USDAの統計データと比較する。

推定期間は、CDLが全米で整備されている2008年から2013年とする。単収推定モデルは、隠れ層6層のDNNを利用する。

6.4 ダウンスケーリング結果と検証

6.4.1 USDAの郡レベルの収穫面積とCDLの比較

本研究のダウンスケーリングではCDLを用いるため、CDLのトウモロコシ畑とUSDAのトウモロコシ収穫面積とどのような関係があるか比較評価した。評価するための処理手順は、図6.1で示す。本研究の研究範囲はアメリカとなっており、広域のため面積集計を容易するため、CDLの投影法をSinusoidal (SIN)へ変換する。SINは、MODISで採用されている投影法であり、異なる緯度でも衛星画像のピクセルが持つピクセルの距離は変わらないように定義されている。投影変換されたCDLを郡ごとで都もろこし畑のピクセルを集計し、面積を算出した。USDAから公開されている収穫面積は単位がエーカー (acre) のため、平方メートルに変換する。以上のようにして処理したCDLとUSDSAのトウモロコシ面積を比較し、単収をダウンスケーリングした際の評価の考察に加える。

図6.2に郡ごとで集計したCDLのトウモロコシ畑の面積とUSDAによるトウモロコシの収穫面積の散布図を示す。CDLは2008年のものを用いた。集計した結果、CDLのトウモロコシ畑の面積の方がUSDAで報告されているトウモロコシ収穫面積よりも大きい傾向にあった。

6.4.2 ダウンスケーリングの結果

図6.3に2008年のトウモロコシ単収をダウンスケーリングしたマッピングを示す。図6.4はUSDAで公開されている2008年のトウモロコシ単収である。図6.5と6.6は2012年のマッピングである。このダウンスケーリング結果を郡ごとで再集計した単収を図6.7、収穫量を図6.8に示す。単収を再集計した結果では、USDAの郡レベル単収が200 (bushels/km²) 以上の場

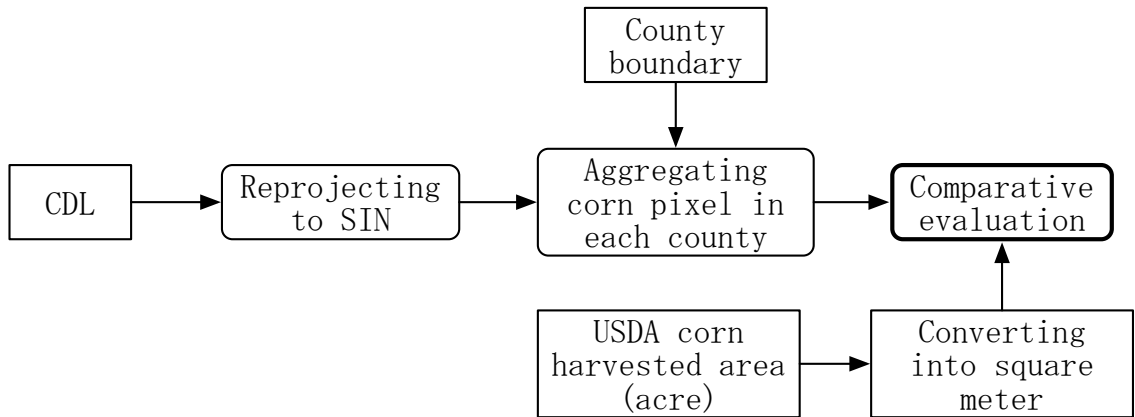


図 6.1 CDL と USDSA のトウモロコシ収穫面積の比較評価の流れ




図 6.2 CDL のトウモロコシ畑面積と USDSA の収穫面積

合、過少推定となっている。そのほとんどの郡が USDSA の収穫面積と CDL が示すトウモロコシ畑面積が非常に小さく、生産規模がわずかな地域であった。収穫量で再集計した結果は、単収をダウンスケーリングしたデータから算出したものの方が、USDSA のデータより大きい傾向にあった。これは CDL のトウモロコシ畑から郡単位で集計した面積が USDSA の収穫面積よりも大きいことが理由だと考えられる。

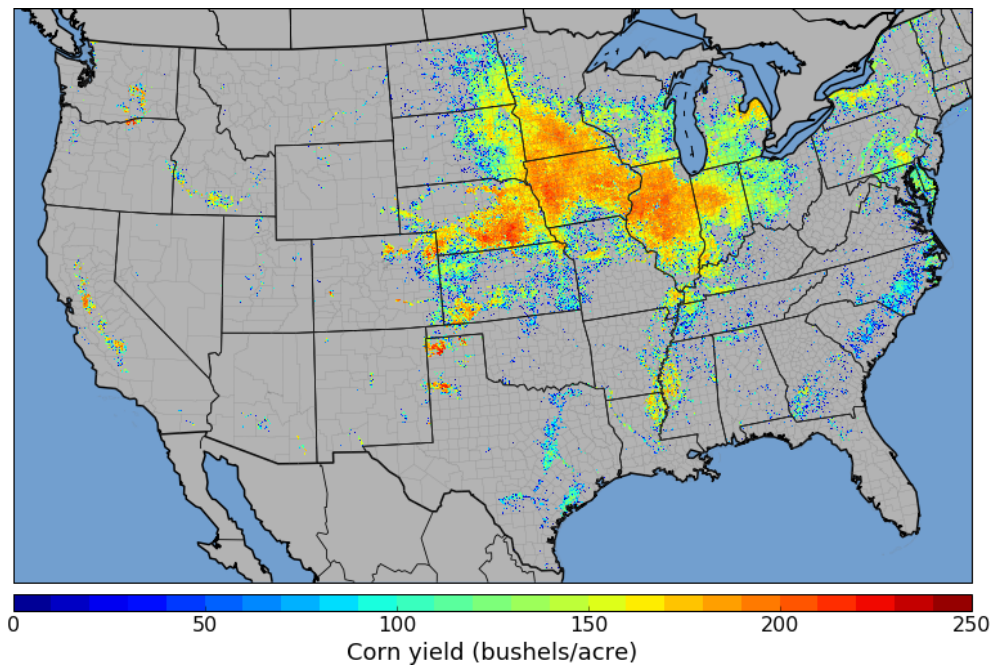


図 6.3 トウモロコシ単収のダウンスケーリング結果 (2008 年)

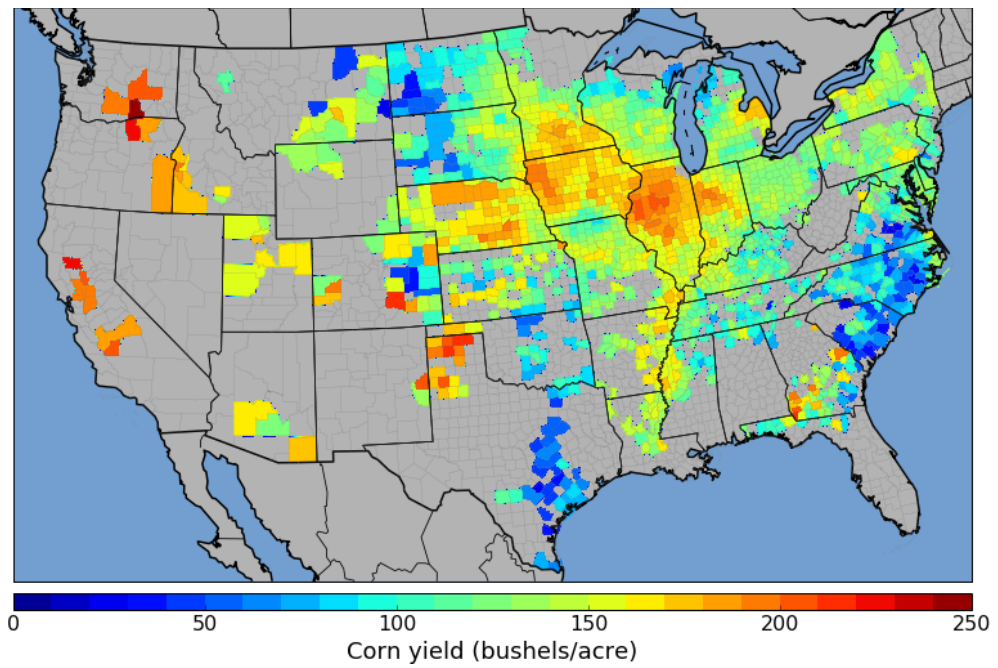


図 6.4 USDA のトウモロコシ単収 (2008 年)

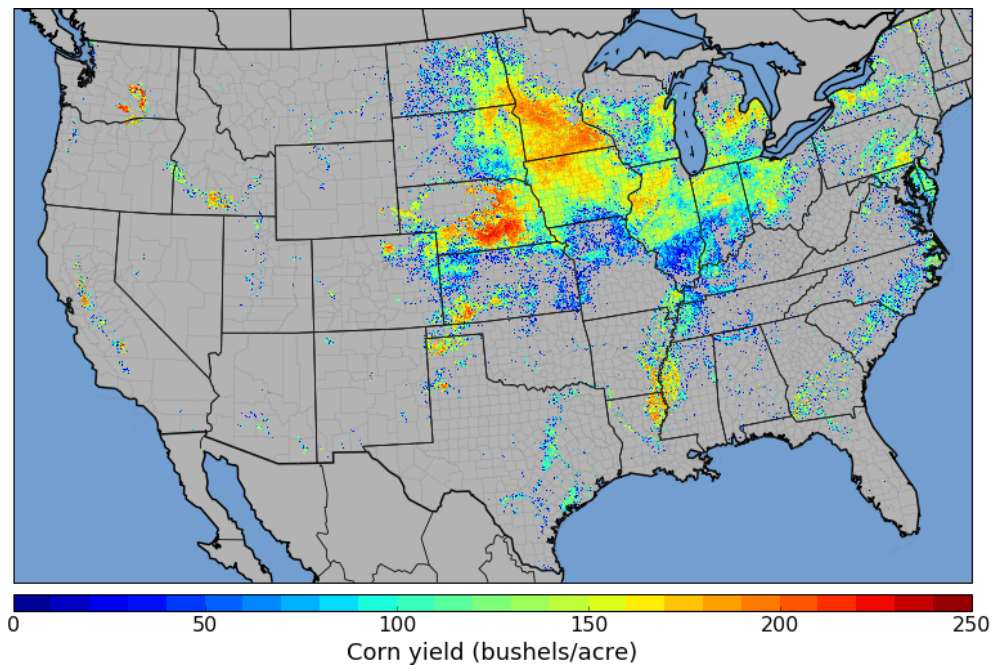


図 6.5 トウモロコシ単収のダウンスケーリング結果 (2012 年)

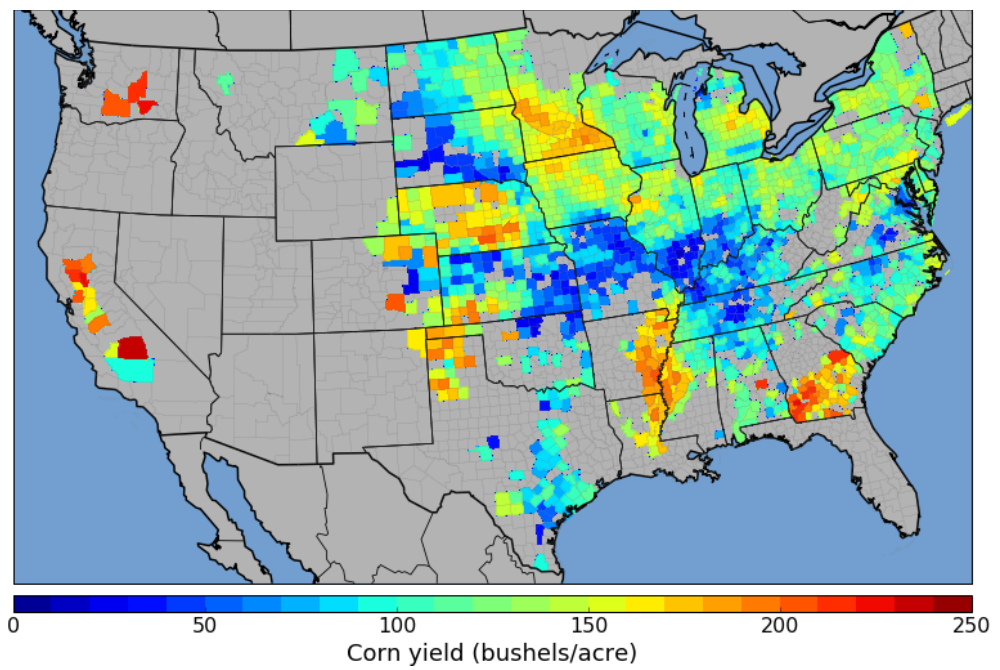


図 6.6 USDA のトウモロコシ単収 (2012 年)




図 6.7 郡ごとで再集計したダウンスケーリング単収と USDA の単収（2008 年）




図 6.8 郡ごとで再集計したダウンスケーリング収穫量と USDA の収穫量（2008 年）




図 6.9 郡ごとで再集計したダウンスケーリング単収と USDA の単収（2012 年）




図 6.10 郡ごとで再集計したダウンスケーリング収穫量と USDA の収穫量（2012 年）




図 6.11 ダウンスケーリングした単収と USDA の単収のヒストグラム (2008 年)

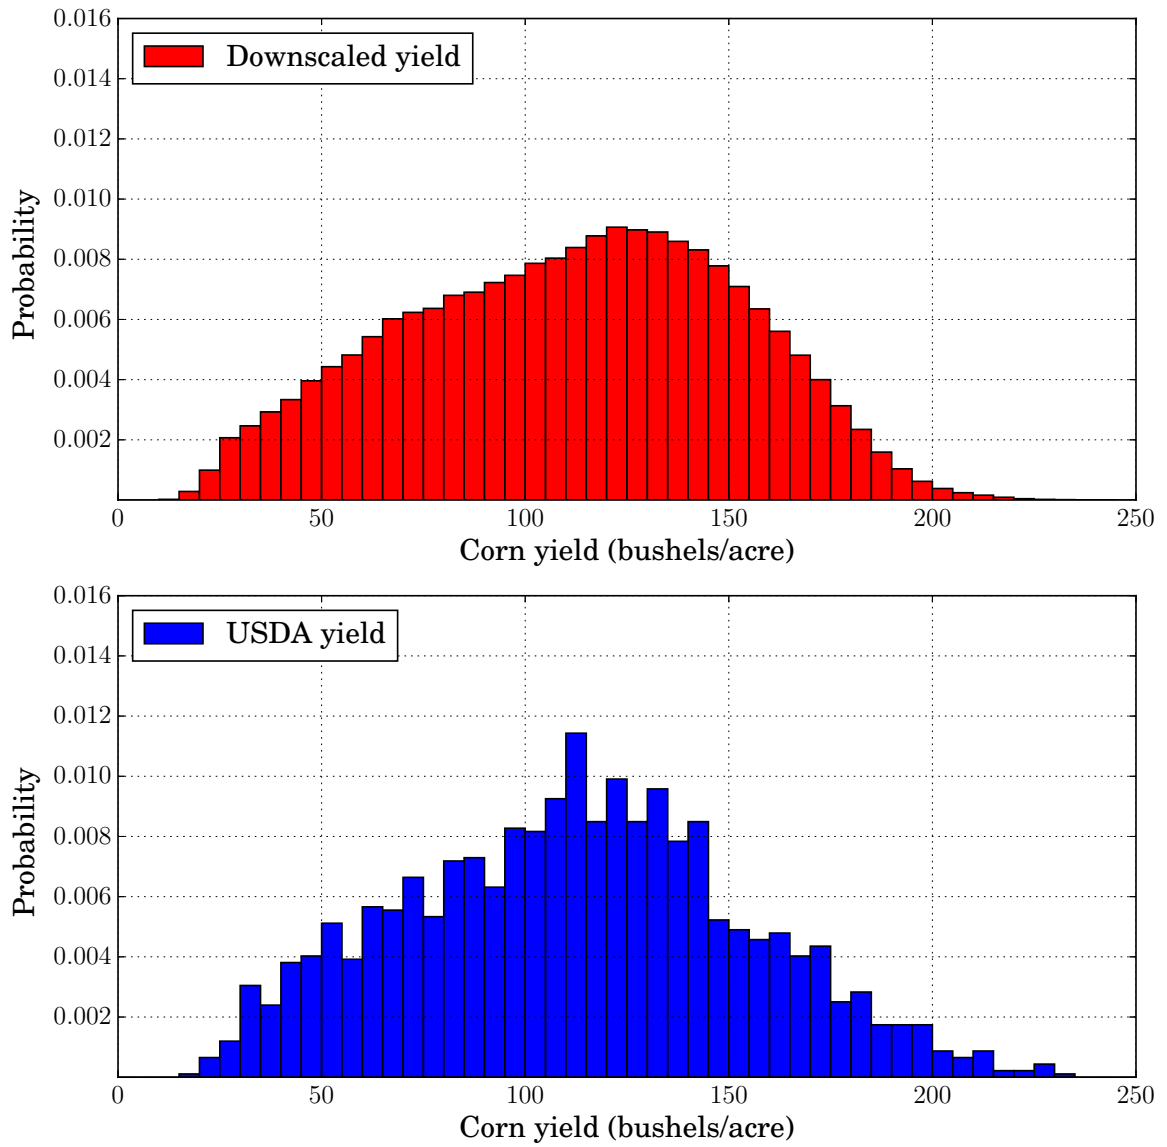


図 6.12 ダウンスケーリングした単収と USDA の単収のヒストグラム (2012 年)

6.5 単収ダウンスケーリングの考察

図 6.7 と 6.9 の単収の散布図において、ダウンスケーリングした単収は USDA の郡レベルの単収と比較すると過少の傾向にある。歴史的な干ばつで深刻な減収が発生した 2012 年では特に、ダウンスケーリングした単収は過少傾向が強い。

図 6.3, 6.5 の単収のダウンスケーリング結果を図 6.4, 6.6 の単収の分布をそれぞれ比較すると、コーンベルトやその周辺地域での値の空間的分布がよく似ていることがわかる。しかし、コーンベルト以外のジョージア州やアラバマ州などの南東部、ペンシルバニア州やニューヨーク州などの北東部などの地域では、USDA のデータでは多くの郡のデータが得られているが、CDL のトウモロコシ畑が存在しない郡がある。さらに、北西部のワシントン州やオレゴン州では、USDA の単収は非常に高いが、収穫面積および CDL のトウモロコシ畑の面積は非常に小規模となっている。

図 6.11 から 6.12 のヒストグラムでも値の分布は似ているが、1km メッシュは郡単位のデータのサンプル数と比べると大きいので、ダウンスケーリングした単収の方が分布がなめらかである。また凶作であった 2012 年は、普通の作柄であった 2008 年に比較すると全体的に単収が小さい分布を示していることがわかる。

よって、USDA の郡レベル単収と比較することで、単収のダウンスケーリングはコーンベルトなど生産規模が大きい地域において妥当な結果が得られていると考えられる。しかし、生産規模が小さい地域や CDL のトウモロコシ畑の面積が小さい地域では、ダウンスケーリングした単収は過少の傾向にあった。ダウンスケーリングを適用した単収推定モデルは、CDL のトウモロコシ畑でマスキングした入力データで学習している。トウモロコシ畑が集積していない地域では、データの空間代表性が低くなりトウモロコシの情報を十分に得られなかったことが考えられる。

また、単収をダウンスケーリングし、マッピングすることで、単収の状況を郡レベルよりも詳細に把握することが可能になった。ベースリスクが大きな課題となるインデックス型農業保険において、単収のダウンスケーリングはベースリスクの低減効果に期待できる。

第7章 単収推定モデルによる単収推定保険の開発

7.1 本研究で適用する単収推定保険の考察

インデックス型保険は、査定で補償金が決定される従来型と比べて、保険会社と農家の情報格差によって生じる逆選択やモラルハザードのリスクが低い。これは、保険会社や農家がコントロールすることができないインデックスを保険計算に取り入れているからである。インデックス型保険は、天候インデックス保険と単収インデックス保険が存在する。

7.1.1 天候インデックス保険の考察

天候インデックス保険は、気象観測ステーションで観測される気象パラメータをインデックスとし、観測しているインデックスが条件を満たした時、被保険者に補償金が自動的に支払われる仕組みである。例えば、干ばつによる作物の減収を補償する場合、7月の積算降水量が80mmを下回ったら自動的に補償金が支払われる。干ばつの深刻具合によって、インデックスの閾値を多段階的に設定し、複数の補償レベルを設けることが可能である。

天候インデックスは収量のサンプル調査が不要となるため、保険のコストが下がるという大きなメリットがある。さらに、農家がコントロールすることのできない気象データをインデックスにするため、逆選択やモラルハザードといった問題を回避することが期待できる。また、インデックスが条件に適合することで自動的に支払いが発生するので、資金が即時に得られるという農家にとって大きなメリットも存在する。

天候インデックスを設計する際に最も重要な点は、作物収量との相関関係である。気象観測ステーションがまばらで被保険者の農地がステーションと離れていたり、作物減収に対し天候インデックスが連動しなければ、補償金の未払いもしくは過払いが発生し、農家が保険へ加入するインセンティブが下がってしまう。このような補償金と実際の損害の乖離を発生させるリスクをベシスリスク (1.2.3) とよび、インデックス保険の最大の課題といわれている。近年では、衛星データから観測した降水量のメッシュデータを天候インデックスに取り入れるパイロットプロジェクトが行われた。衛星は、地表を連続的に観測することが可能であるが、空間分解能の高さや観測頻度が異なり、運用期間が限られているため、複数のデータプロダクトを組み合わせる必要があると考えられる。

第2章で行った天候インデックス分析では、天候インデックスを地域ごとで作成する必要がある

あることが分かった。さらに、得られる気象データも地域で異なるため、収量に対してより強い相関関係を持つ特徴量を形成するためには、気象パラメータの解析を各地域で個別に行う必要がある。図 2.17 を確認すると、気象パラメータとトウモロコシの作柄の相関関係は、郡の間の距離（およそ 30 から 50km）で異なることがわかる。ベースリスクを低減するためには、少なくとも郡レベルのスケールで天候インデックスを設計する必要がある、その作業は非常に煩雑になる可能性がある。さらに保険設計に大きなコストが必要になると懸念される。

そして、天候インデックス保険は、天候不順によって減収するリスクを補填することは可能であるが、価格のリスクはカバーすることはできない。多くの場合、農作物は市場によって取引されるため、供給量と需要量で価格が決定される。よって、天候に恵まれたシーズンでは豊作となり、供給量が需要量を多く上回り、価格が暴落するケースがある。農業活動の長期的安定を目指すためには、価格リスクの考慮も必要である。

7.1.2 単収推定保険の考察

単収インデックス保険は、被保険農地から限られた範囲（自治体など）の平均収量が過去数年の平均収量を下回った場合に支払われる保険である。よって、被保険農地だけが収量が落ち込んでも補償金の支払いは発生しないが、インデックスが周辺地域の単収であるため、逆選択やモラルハザードを回避することが可能である。台風や干ばつなど広域にわたって影響を及ぼすリスクの補填には有効であるが、病虫害など局所的なリスクには対応が難しい。また、減収のリスクはカバーされているが、天候インデックス保険と同様に価格リスクはカバーされていない。

サンプル調査を行うため、査定に対するコストが必要となる。また、収穫後に査定を実施するため、補償金の支払いが収穫時期の 3ヶ月後となり、天候インデックス保険と比べ、支払い時期が遅い。

単収インデックス保険は、保険の仕組みがシンプルであり、従来型保険の課題が改善されている。しかし、実際に扱われているのはわずかで、アジアではインドのみとなっている (FAO, 2011)。

7.1.3 本研究が適用する農業保険

以上より、農業保険を設計する上で、「ベースリスク」、「査定コスト」、「支払いタイミング」、さらに「価格リスク」は重要なポイントである。本研究では、それらを念頭に置くことで、新しい農業保険を提案する。

第 4 章では、衛星データと深層学習を用いることで全米のトウモロコシを郡レベルで高精度に推定することが可能となった。深層学習をはじめとする機械学習は、ターゲットデータを推定するための特徴量を入力データから抽出する能力に長けているため、7.1.1 で述べた天候インデックスを作成するための煩雑な作業を必要としない。さらに第 6 章で行った単収ダウンス

ケーリングを組み合わせることで、ベースリスクの低減が期待できる。また、従来のようなサンプル調査をせず、作物単収を推定することが可能になるため、査定コストの削減に期待できる。さらに収穫直後に収量推定を行うことで、補償金の迅速な見積もりに貢献し、査定付きの保険より支払いのタイミングを早めることが期待できる。

価格リスクは、作物減収リスクをカバーする保険では補填が難しい。唯一、価格リスクの補填を行っているのは、作物収入保険であるため、補償金計算の方法に作物収入保険の仕組みを取り入れる必要があると考える。

7.2 本研究が開発する農業保険

7.2.1 収入保証保険

本研究では、アメリカの収入保証保険（Revenue Protection Insurance）や Group Risk Protection（GRP）を参考にし、保険の計算を行う。収入保証保険は、単収の減少と価格下落による収入の減少を一定の水準まで保証する保険商品である。

収入保障保険は、式（7.1）から（7.3）で計算される。

$$g = y_b \times p_e \times l \quad (7.1)$$

$$r = y_x \times p_m \quad (7.2)$$

$$I = \begin{cases} g - r & (g > r) \\ 0 & (g \leq r) \end{cases} \quad (7.3)$$

g は作付け前に計算される収入保証額、 y_b は基準単収で過去4から10年の郡の平均単収、 p_e は作付け前の先物市場価格、 l は保証水準で70%から90%まで5%段階で農家が設定する。 r は収穫後に計算する算定収入額、 y_x は収穫時のトウモロコシ単収で本研究のダウンスケーリング単収を適用させる。 p_m は収穫時の市場価格である。 p_e と p_m は全米一律の価格を適用させる。 I は被保険者に支払われる補償金であり、収入保証額が算定収入額を上回っていた場合に収入保証額と算定収入額の差額が支払われる。

この収入保証保険は、先物市場価格と郡レベルの単収を取り入れているため、逆選択やモラルハザードの問題が回避される。さらに、本研究の深層学習による単収推定とダウンスケーリングを適用することで、ベースリスク、コスト、支払いタイミングの問題を解決できると考えられる。

7.2.2 本研究の収入保証保険の評価

本研究が計算する 7.2.1 の収入保証保険を評価するため、トウモロコシの減収や価格の下落などによって減少する農家の収入を保証することができたかを評価する。評価方法は、以下の式 (7.4) と (7.5) を計算し、農家が得られる利益を推計する。

$$o = r - c \quad (7.4)$$

$$p = o + I \quad (7.5)$$

o は算定収入額 r から栽培コスト c を差し引いた営業利益である。 p は営業利益 r に補償金額 I を加算した利益である。赤字であった営業利益が保険の補償金が支払われたことで黒字に転換したかを確認し、本研究の収入保証の補償能力を評価する。

7.2.3 保険計算に用いるデータ

7.2.1 と 7.2.2 を計算するために必要なパラメータは、表 7.1 で示すものを適用する。

予測価格は、USDA Risk Management Agency (RMA) の Group Risk Plan (GRP) の最終支払い報告でされている期待価格を適用する。作物ごとに郡単位のデータがウェブサイト¹で取得することが可能である。収穫時価格および栽培コストは、USDA ERS (Economic Research Service) のウェブサイト²で公開されているデータを用いた。栽培コストの内訳は、表 7.2 の通りである。これは、第 3 章の天候インデックス保険を評価する際に用いたコストと同様である。

表 7.1 保険計算で扱うパラメータ

パラメータ	取得方法
基準単収 (y_b)	USDA の郡レベルの 4 年平均単収
予測価格 (p_e)	USDA RSA で報告されている GRP の期待価格
補償水準 (l)	本研究では 80% と設定
収穫時単収 (y_x)	本研究でダウンスケーリングした単収
収穫時価格 (p_m)	USDA ERS で報告されている取引価格
栽培コスト (c)	USDA ERS で報告されている Heartland 地方のトウモロコシ栽培コスト

¹<http://www.rma.usda.gov/data/grpfinal/>

²<http://www.ers.usda.gov/data-products/commodity-costs-and-returns.aspx>

表 7.2 栽培コストの内訳

Operating costs	Seed Fertilizer Chemicals Custom operations Fuel, lube, and electricity Repairs Interest on operating capitals
Allocated overhead	Hired labor Opportunity cost of unpaid labor Capital recovery of machinery and equipment Opportunity cost of land (rental rate) Taxes and insurance General farm overhead

7.2.4 保険計算の対象

保険計算の対象地域は、コーンベルト周辺の CDL のトウモロコシ畑とした。期間は、CDL が全米で整備されている 2008 年から 2013 年までとした。

7.3 収入保険の計算結果

図 7.1 から 7.35 まで、営業利益、収入保険の補償金、利益の推計とそれぞれのヒストグラムを示す。ヒストグラムで示す Annual（平年）は、2008 年から 2013 年の平均値を各メッシュで計算したものである。

7.3.1 2008 年の結果

2008 年は、平年並みの作柄であった。営業利益は全体的に 200 ドルとなっており（図 7.1）、ヒストグラムでは平年よりも高い営業利益を示している（図 7.2）。補償金は全体的に 400 ドルほどとなっており（図 7.3）、平年よりも低い分布となっている（図 7.3）。利益は、コーンベルトの中心では 600 ドルほどとなっており、600 ドル後半を得ている地域も一部あった（図 7.5）。ヒストグラムでは、平年とほぼ同じ分布を示していたが、600 ドル後半の利益を得ていたサンプルは少なかった（図 7.6）。

7.3.2 2009 年の結果

2009 年は、平年よりも良い作柄であった。営業利益の分布（図 7.7）はほぼ均一の値を示している。図 7.8 のヒストグラムでは、最頻値の額が平年分布より小さく、分散も小さい。支払われる補償金も平年と比較すると全体的に小さい結果になった（図 7.9, 7.10）。利益は平均して 600 ドルほどで、平年分布より小さい結果となった。

7.3.3 2010 年の結果

2010 年の営業利益は、平年と同じ分布をしており（図 7.13）、ヒストグラムからも確認できる（図 7.14）。補償金は全体的に 400 ドルであるが、イリノイ州中西部とアイオワ州東部では 500 ドルほどで若干高くなった（図 7.15）。ヒストグラムでも 2009 年の補償金は、平年と比較して低かったことがわかる（図 7.16）。利益は、全体的に 500 ドル後半となっており（図 7.17）、他の年と比較しても 500 ドル後半の頻度が突出している（図 7.18）。

7.3.4 2011 年の結果

2011 年は平年よりも若干悪い作柄であった。営業利益はアイオワ州の中心部やネブラスカ州で 600 ほどで高い地域もあり、大部分が 200 ドル後半となっていた（図 7.19）。ヒストグラムでも、2011 年は平年の営業利益よりも高い分布を示している（図 7.20）。補償金は一部 400 ドルを下回る地域もあるが、600 ドルほどが大部分だった（図 7.21）。ヒストグラムでは、平年とほぼ同じ分布を示している（図 7.22）。利益はほとんどの地域で 700 から 900 ドルとなってお

り、コーンベルトの中心地域で高い値を示している（図 7.23）。ヒストグラムでも平年と比較して高い利益を得たことがわかる（図 7.24）。

7.3.5 2012 年の結果

2012 年は、歴史的な大干ばつが発生し、コーンベルトの州のほとんどの作柄が深刻な凶作であった。営業利益は、イリノイ州南部などで-500 ドルと大きな損失を出しているが、ネブラスカ州やミネソタ州で 600 ドル以上の高い営業利益を得ている地域も一部存在する。（図 7.25）。ヒストグラムでは、平年の分布と大きく異なり、最大で-600 ドルほどの損失からおよそ 800 ドルの利益を出している場合もあり、分散が非常に大きい分布となっている（図 7.26）。補償金は、図 7.25 で損失を出している地域に対して大きく支払われており、営業利益が高かった地域は補償金が小さい空間分布になっている（図 7.27）。ヒストグラムでは、図 7.26 と同じように分散が非常に大きい分布となっている（図 7.28）。2012 年は、大干ばつの影響でトウモロコシの取引価格が急騰したことで、平年並みの作柄の地域は高い営業利益を得られたが、壊滅的な被害を受けた地域では多額の補償金が支払われたということが確認できる。利益は、大部分の地域で 700 から 900 ドルとなった（図 7.29）。ヒストグラムでも、平年分布よりも 2012 年の利益分布は右ヘシフトしていることから、全体的に多くの利益を得たことがわかる（図 7.30）。

7.3.6 2013 年の結果

2013 年は、平年よりも良い作柄となった。全体的に 100 ドルを割る営業利益となっており、損失を被る地域もあった（7.31）。ヒストグラムでも平年と比較し、若干小さくなっており、損失をだしている確率も高かった（図 7.32）。補償金は、営業利益の損失を補填する形で支払われており（図 7.33）、平年よりも高い補償金が高い確率で支払われている（図 7.34）。利益は、ほとんどの地域で 600 から 900 ドルの空間分布を取っている（図 7.35）。ヒストグラムでも右ヘシフトしているため平年より高い利益を多く出しているが（図 7.36）、2012 年の方が 800 ドルの利益を得る確率が高かった。




図 7.1 トウモロコシ栽培による営業利益推計 (2008 年)




図 7.2 トウモロコシ栽培による営業利益推計のヒストグラム (2008 年)

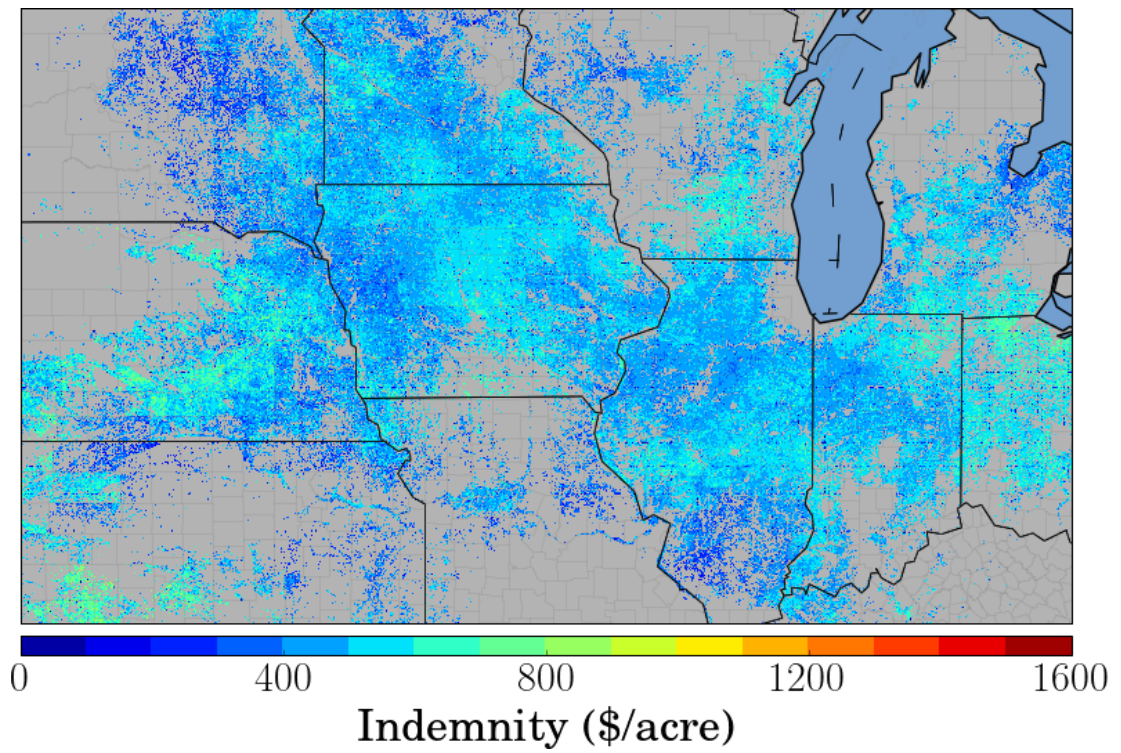


図 7.3 本研究の収入保険による補償金推計 (2008 年)




図 7.4 本研究の収入保険による補償金推計のヒストグラム (2008 年)




図 7.5 トウモロコシ栽培による利益推計（2008年）




図 7.6 トウモロコシ栽培による利益推計のヒストグラム（2008年）




図 7.7 トウモロコシ栽培による営業利益推計 (2009 年)




図 7.8 トウモロコシ栽培による営業利益推計のヒストグラム (2009 年)




図 7.9 本研究の収入保険による補償金推計 (2009 年)




図 7.10 本研究の収入保険による補償金推計のヒストグラム (2009 年)




図 7.11 トウモロコシ栽培による利益推計 (2009 年)




図 7.12 トウモロコシ栽培による利益推計のヒストグラム (2009 年)




図 7.13 トウモロコシ栽培による営業利益推計 (2010 年)




図 7.14 トウモロコシ栽培による営業利益推計のヒストグラム (2010 年)




図 7.15 本研究の収入保険による補償金推計 (2010 年)




図 7.16 本研究の収入保険による補償金推計のヒストグラム (2010 年)




図 7.17 トウモロコシ栽培による利益推計 (2010 年)




図 7.18 トウモロコシ栽培による利益推計のヒストグラム (2010 年)




図 7.19 トウモロコシ栽培による営業利益推計 (2011 年)




図 7.20 トウモロコシ栽培による営業利益推計のヒストグラム (2011 年)




図 7.21 本研究の収入保険による補償金推計 (2011 年)




図 7.22 本研究の収入保険による補償金推計のヒストグラム (2011 年)

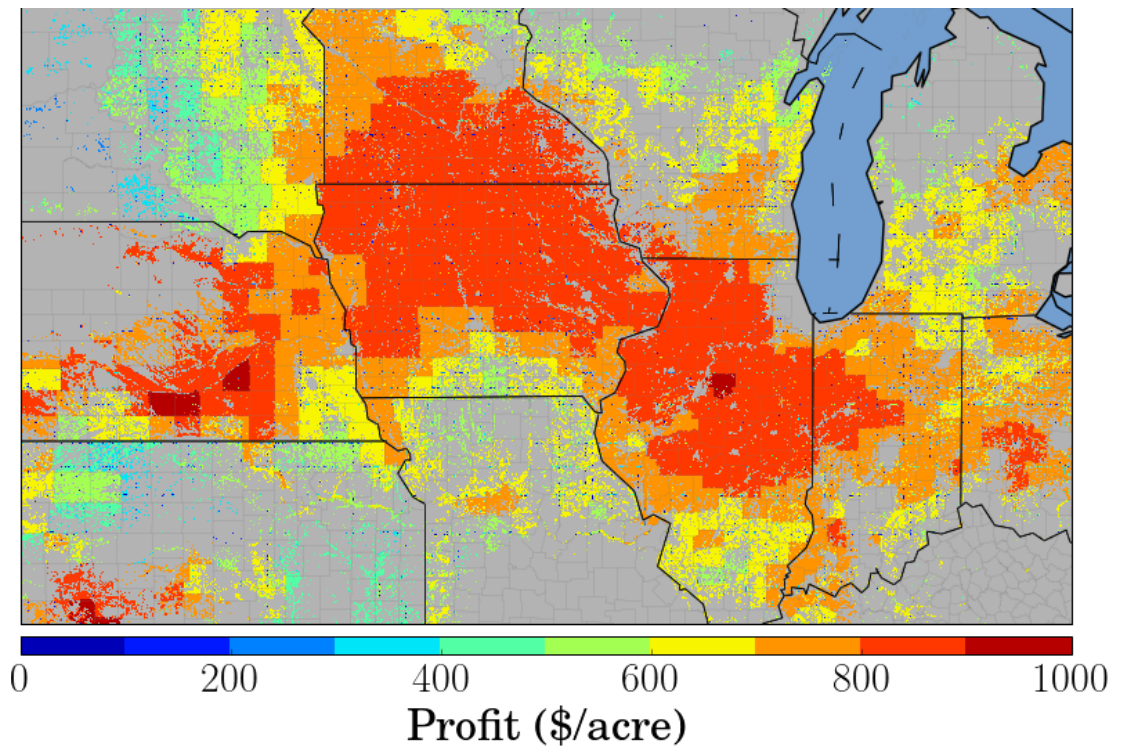


図 7.23 トウモロコシ栽培による利益推計 (2011 年)




図 7.24 トウモロコシ栽培による利益推計のヒストグラム (2011 年)

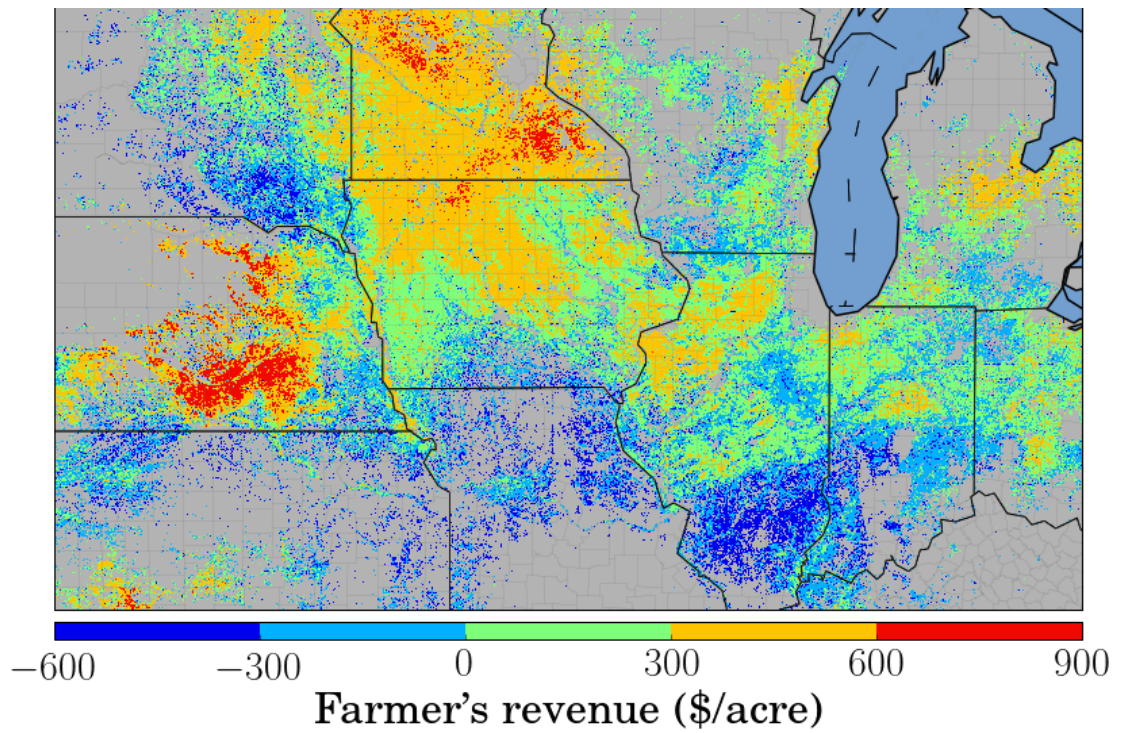


図 7.25 トウモロコシ栽培による営業利益推計 (2012 年)

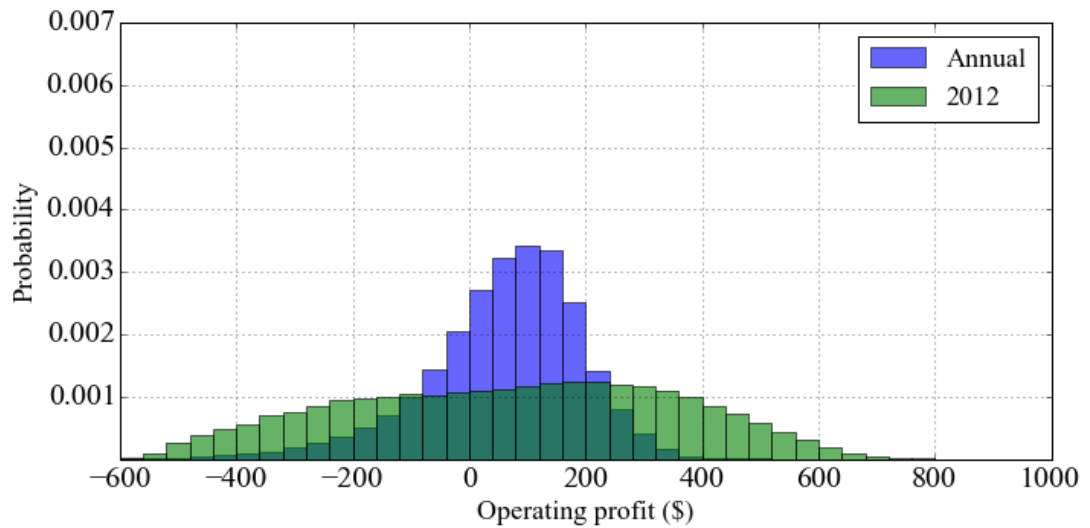


図 7.26 トウモロコシ栽培による営業利益推計のヒストグラム (2012 年)




図 7.27 本研究の収入保険による補償金推計 (2012 年)




図 7.28 本研究の収入保険による補償金推計のヒストグラム (2012 年)




図 7.29 トウモロコシ栽培による利益推計 (2012 年)

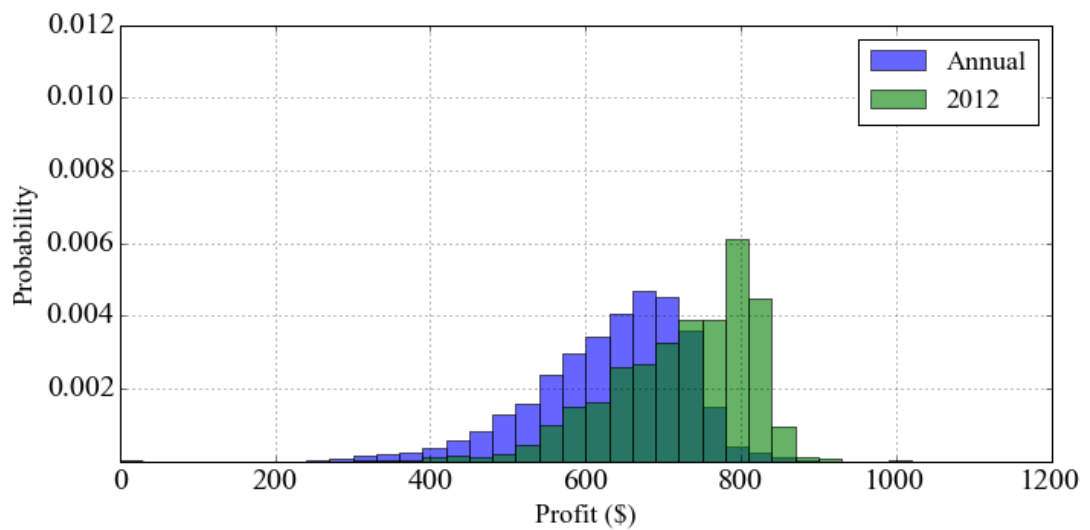


図 7.30 トウモロコシ栽培による利益推計のヒストグラム (2012 年)




図 7.31 トウモロコシ栽培による営業利益推計 (2013 年)




図 7.32 トウモロコシ栽培による営業利益推計のヒストグラム (2013 年)




図 7.33 本研究の収入保険による補償金推計 (2013 年)




図 7.34 本研究の収入保険による補償金推計のヒストグラム (2013 年)




図 7.35 トウモロコシ栽培による利益推計 (2013 年)




図 7.36 トウモロコシ栽培による利益推計のヒストグラム (2013 年)

7.4 本研究の農業保険の考察

7.4.1 ベーシスリスクの改善について

衛星データと深層学習による本研究の単収ダウンスケーリング手法を用いて、収入保証保険を算出し、営業利益に加算することで、利益を向上させることが確認できた。郡レベルの平均単収を1 kmにダウンスケーリングすることで、空間的により詳細な補償金の算出が可能になった。これによってベーシスリスクの改善が期待できる。生産規模の小さい地域は、単収の過少推定の傾向があったため、過払いの可能性がある。今後はそのような地域でも高精度な推定を成すため、改善が必要である。例えば、気象や衛星からの植生情報以外にも土壌や農地の集積具合などといった情報を深層学習の推定モデルに取り入れることが考えられる。ダウンスケーリングしたことで、単収推定のための特徴量形成に気象や植生情報以外別のデータが必要だったことが考えられる。

7.4.2 従来保険の課題解決について

従来保険の課題であった、逆選択、モラルハザードやコスト、支払いタイミングは、本研究の手法を取り入れることで解決が期待できる。

本研究の収入保証保険には、市場価格と郡の過去の平均単収を取り入れているため、農家が操作することは不可能であることから、逆選択やモラルハザードの問題は回避できると考えられる。保険の補償金を算出する際、第三者にはコントロールすることができない透明性のある指標を使用することは、非常に重要である。本研究で算出した収入保証保険も収入保証額 g がインデックスの役割を担っているため、一種のインデックス型保険といえる。

本研究では、衛星データや深層学習で単収を広域に推定しているため、従来型のサンプル調査による査定は必要としない。よって、コストの削減に貢献できると考えられる。また、収穫直後に推定モデルを適用することで、保険の補償額を即座に計算することが可能であるため、従来の収穫3ヶ月後の支払いタイミングよりも迅速な対応が可能である。

また、本研究の補償額は、営業利益の分布とは逆の分布となり、本研究の収入保証保険を適用することで、収益を確保することが可能となった。作物減収のリスクを補填する保険は、干ばつや洪水による被害を補填することは可能であったが、豊作貧乏などによる収益損失は保証されなかった。2012年の歴史的な大干ばつの発生によって、収益を上げる地域もいれば、大きな損失を被る地域もいた。作物市場価格は全米で一律をとっているため、大規模な自然災害が発生すると、このような地域差が顕著に表れてしまう。

7.4.3 本研究の新規性

深層学習による単収推定モデルを農業保険に適用した研究報告はまだない。深層学習は、アルゴリズムによってデータから特徴量を自動的に抽出するため、ブラックボックス化による利

用者の懐疑心が懸念される。他の単収推定手法として、作物生長モデルの利用が挙げられるが、4.1.3でも述べた通り、保険へ導入するためには、データの可用性という大きな問題が存在する。さらにアルゴリズムが自動的に支払いを決定するため、人によって起因するリスクの軽減が期待される。よって、深層学習をはじめとする機械学習による作物単収推定は、新しい農業保険の開発に有効であると考えられる。

また、単収のダウンスケーリングによって1km間隔で補償金を算出した事例もまだ報告されていない。天候インデックス保険で利用する気象観測ステーションの設置間隔は、日本でおおよそ20kmといわれている。既存の面積当たり収量保険は、郡単位で実施されているので、アメリカのコーンベルト地域では35から50kmの大きさになる。数十kmの距離では、地域によって気象条件や土壌環境も変わり、単収も大きく変動する可能性がある。ベースリスクを軽減するためには、観測データの分解能向上などが必要であるが、気象観測ステーションの設置増強などといった対処ではコストが増し、トレードオフとなってしまう。衛星データや機械学習などの技術を取り入れることで、ベースリスクをはじめとするインデックス保険の課題解決に期待する。

第8章 天候インデックス保険と単収推定保険の比較

8.1 カバー率の計算

損害の保証状況进行评估する際、カバー率がよく用いられており、保険設計を行う上でも重要な設計変数として考えられている(多々納, 2003)。カバー率は、保険による支払額を損失額で除算した比率で求める。

2011年から2012年にかけて、ラニーニャ現象が発生したことで、2012年にアメリカで深刻な干ばつが発生した。アメリカ大陸のおよそ65%が干ばつに見舞われ、約300億ドルの被害が農業分野で被った(Rippey, 2015)。大干ばつの発生に伴い、173億ドルの保険金支払いが発生し、75%の農地が補償された(Rain and Hail Insurance Society, 2016)。この補償金額は、農業分野において歴史的に最も巨額な金額となった。2013年は、トウモロコシは豊作の年であったが、価格が低下することによって、農家の利益は減少し、およそ120億ドルの保険金支払いが発生した。

以上のように、農業保険は、気候災害以外の減収事象に対して保証が実行される必要がある。本研究が提案した単収推定保険(第7章)の保証状況进行评估するため、保険金額を損失額で除算して求めたカバー率を算出し、天候インデックス保険の場合(第3章)と比較した。

8.2 天候インデックス保険と単収推定保険のカバー率の結果

表8.1に天候インデックス保険と単収推定保険のカバー率を比較した結果を示す。

天候インデックス保険の場合、2008、2009、2013年において、保険金の支払いが実行されなかったが、農家は損失を被っていた事がわかる。2010年では、支払いがされているが、損失を完全に補填するほどの十分な支払いはされていない。2011年と2012年では、多額の保険金支払いが実行され、損失をカバーしたことが確認された。しかし、損失額に応じた適正の支払いが発生しておらず、農家の利益格差は拡大する結果となった(図7.30, 7.36)。

本研究が提案する単収推定保険では、全ての年において保険金支払いが実行されており、農家の損失を補填したことが確認された。しかし、損失金額のおよそ10倍以上の保険金が支払われており、過払いの懸念がある。

8.2. 天候インデックス保険と単収推定保険のカバー率の結果

表 8.1 天候インデックス保険と単収推定保険のカバー率

年	天候インデックス保険 (郡レベル)		単収推定保険 (1km メッシュ)			平均単収	収穫価格
	損失額	保険金	カバー率	損失額	保険金		
2008	\$ 92 K	\$ 0	0%	\$ 2,077 K	\$ 20,080 K	966.7%	\$ 4.34 (bu./acre)
2009	\$ 38 K	\$ 0	0%	\$ 5,066 K	\$ 48,300 K	953.5%	\$ 3.61 (bu./acre)
2010	\$ 74 K	\$ 5.8 K	7.8%	\$ 5,889 K	\$ 37,936 K	644.2%	\$ 4.33 (bu./acre)
2011	\$ 153 K	\$ 229 K	149.5%	\$ 4,037 K	\$ 26,887 K	666.0%	\$ 5.70 (bu./acre)
2012	\$ 124 K	\$ 338	272.9%	\$ 33,773 K	\$ 141,954 K	420.3%	\$ 6.82 (bu./acre)
2013	\$ 41 K	\$ 0	0%	\$ 20,536 K	\$ 133,803 K	651.5%	\$ 4.59 (bu./acre)

8.3 考察

天候インデックス保険では、インデックスが条件を満たさない場合、保険金支払いが実行されないため、農家が損失を被っても補償されない可能性が十分にある。例えば、気温をインデックスとした天候インデックス保険を購入した場合、洪水による減収リスクはカバーされない。さらに、アメリカでは、気候災害以外にも価格リスクなど様々な減収のリスクが存在する。また、インデックスは作物単収との完璧な相関を有していないことから、農家が被る損失に応じた保険金支払いが非常に困難といえる。図 3.19 と 3.21 を確認するとおり、営業利益に応じた適正な保険金支払いが成されていないため、保険によって農家間の利益格差が推計される（図 3.23）。

本研究が提案する単収推定保険は、単収を直接的に推定し保険金を見積もるため、あらゆるリスクに対応した収入の保証に期待ができる。図 7.25 と 7.27 を確認すると、天候インデックス保険の場合と異なり、農家の営業利益に応じた支払う保険金の金額が推計されている。表 8.1 でも、天候インデックス保険では補償が行われなかった年でも、単収推定保険は全ての年で保険による損失の補償がされている。しかし、単収推定保険は、カバー率が 400 から 1000% となっており、過度な過払いが発生している。持続的な保険事業を行うためには保険収支が均衡するように設計する必要があるため、適正な保険金支払いが望ましく、過払いは保険会社に対して経営圧迫を強いることとなる。日本やアメリカでは、農業保険に要する事業費の半分が国の援助によって賄われているが、過剰な保険金支払いは国の事業費に多大な負担を強いることが懸念される。単収推定保険では、単収を推定することで農家の収益を推計することが可能であるため、過払いを防ぐためのより高度な保険金支払いの仕組みを設計することが期待できる。作物の価格設定は、各国の農業制度によって大きく異なるため、保険金価格の設定方法は導入国の状況に応じてデザインする必要がある。

第9章 途上国及び新興国への農業保険導入のための考察

9.1 発展途上国の農業に深刻な被害を与える自然災害の発生

農業にとって、台風、干ばつ、冷害などはリスクの大きい自然災害である。Emergency Events Database (EM-DAT) が取りまとめている世界の災害発生件数と被害総額を図 9.1 に示す。ここでは、洪水 (Flood)、干ばつ (Drought)、地震 (Earthquake)、熱波・寒波 (Extreme temperature) のみを抽出した。特に洪水は、発生件数が増加しており、発生する自然災害の多くを占めている。それぞれの災害で各地域における発生割合を確認すると、どの災害でもアジアで発生する割合が高い (図 9.2 から 9.6)。

洪水の場合、40%がアジアで発生していたことになる。近年、アジアで発生した洪水で特に深刻であったのは、2010年のパキスタン (被害額 53 億ドル)、2011年のタイ (被害額 13 億ドル) とパキスタン (被害額 19 億ドル) といわれている。2010年のパキスタンの洪水では、200万エーカーの農作物が被害を受けた。

干ばつの発生件数が多いのはアフリカであり、アジアやアメリカの2倍以上となっている (図 9.4)。さらに FAO (2015b) は、干ばつが発生することで、農業セクターが受ける被害は、全セクターの 84%を占めると推計している。暴風雨、洪水、津波、地震はそれぞれ、18%、15%、14%、4%としている。2008年から2011年の間にケニアで発生した干ばつが、過去10年間に途上国で発生した干ばつで最も深刻なものとなっており、被害総額は 105 億ドルといわれている。

FAO (2015a) は、48の開発途上国で発生した自然災害を 2003年から2013年の期間でとりまとめた。干ばつ、洪水、暴風雨や津波といった自然災害によって受ける全被害の 22%は農業セクターに関わっている。さらに10年間の農作物への総被害 700 億ドルの内、アジアは 280 億ドルと最も深刻な被害を受け、続いてアフリカでは 260 億ドルとなった。農業によって生計を立てている人は、世界でおよそ 25 億人いるといわれている。そのほとんどの農業従事者が小規模であり、自然災害のリスクにとりわけ脆弱である。

巨大な自然災害が発生すると、多くの場合、国際援助が緊急的に実施される。国際援助は、災害後の復興に大切な役割を果たすが、「継続的なものではない」、「被災者個人へ適切かつ迅速に配分されるものではない」、「各自の力で復興する動機を弱めてしまう」といった欠点が存在する。保険は、主体的なリスク管理を促進するとともに、民間の効率的かつ迅速な金融支援を受けける手法として、非常に有効であると考えられる。

9.1. 発展途上国の農業に深刻な被害を与える自然災害の発生




図 9.1 自然災害の発生件数と被害額

9.1. 発展途上国の農業に深刻な被害を与える自然災害の発生




図 9.2 地域別の洪水発生割合




図 9.3 地域別の暴風雨発生割合




図 9.4 地域別の干ばつ発生割合




図 9.5 地域別の地震発生割合




図 9.6 地域別の熱波・寒波発生割合

9.2 各国の農業保険の導入状況と市場の特徴

以下に、森下 (2014) を参考に取りまとめた各国の農業保険の制度や導入状況を示す。

9.2.1 農業保険の導入状況

FAO (2011) で取りまとめられているアジア周辺地域の農業保険の導入状況を表 9.1 に示す。

最も導入が多い保険は、複合危険作物保険であった。複合危険作物保険は、干ばつや洪水など広域に影響を及ぼすリスクを補填する保険である。これは、作物に被害を与える自然災害は、80%以上が干ばつであるため、必要性が一番高いからだと考えられる。

天候インデックス保険は、2 番目に導入されている保険である。一方で、単収インデックス保険はインドのみで導入されている。単収インデックス保険には、天候インデックス保険のコストが安いというメリットがないため、導入の優位性が小さいと考えられる。

作物収入保証保険は、どの国にも導入されておらず、欧米のみに導入実績がある。作物収入保証保険は、農作物の価格を保険計算に取り入れる。アメリカでは、作物価格の決定に流動性の高い自由市場を取り入れているため、作物収入保証保険が成り立つことが考えられる。政府や組織によって市場価格が調整される場合、逆選択やモラルハザードが発生し、作物収入保証は成り立たないと考えられる。また、アメリカの農地は大規模化が進み、効率化されているため、保険の導入コストが他国と比べ低いことも要因と考えられている。アメリカの農業保険の加入面積では、2013 年時点で収入保証がおおよそ 200 万エーカーで、列挙危険作物保険や複合危険作物保険などの作物保険は 100 万エーカーとなっている。保険金額おおよそ 8 割が収入保証となっており、収入保証が圧倒的な加入率を占めている。また、巨大災害作物保険プログラム (CAT : Catastrophic Crop Insurance Program) という保険制度も用意されている。CAT は、収量が平年の半分を下回るような場合、連邦政府が保険料の全額を負担する。農家は、少額のプレミアムで加入することが可能である。

9.2.2 農業保険の組織形態

農業保険の組織形態は、「Public sector model (PSM : 政府による介入)」、「Public-private partnership (PPP : 官民パートナーシップ)」、「Pure market based (PMB : 完全市場)」の三つのタイプで分けられる。それぞれの特徴を図 9.7 に示す。表 9.2 に各国の農業保険市場の状況を示す。

農業は、国民の衣食を提供する国家の基盤的産業である。さらに、気候変動による影響を受けやすい産業であり、一度、大規模災害によって深刻な損害を被ると連鎖的に他の産業へ波及する可能性がある。よって、全ての保険市場を民営化することは、非常に難しい。特に数十年に一度に発生するような規模の自然災害には、政府が補填するような保険制度が不可欠である。よって、災害規模に応じて損害を保障する仕組みが有効であり、政府の保障による大きな受け皿と民間の効率的な運営をうまく併用することも効果的な方法の一つである。

9.2.3 アメリカの農業保険制度

アメリカの農業保険は、政府主導で民間会社による保険提供の方式を取っている。実施体制として、プレイヤーは、USDA RMA と Federal Crop Insurance Corporation (FCIC：連邦作物保険公社)、民間保険会社であり、その関係を図 9.8 に示す。USDA RMA と FCIC は、再保険の手続き、運営費用補助、指導および監督、新しい保険プログラムの開発や承認が主な役割である。また、農家への保険料補助などをおこなっている。民間保険会社は、保険引き受け、損害評価、新しい保険プログラムの開発やその他顧客へのサービスとなっている。民間保険会社の保険責任のすべてを政府が再保険するのではなく、一部を海外の民間再保険会社が請け負う。政府は、民間保険会社の業務費用の一部拠出したり、農業保険の推進費用や教育費用を負担することで、農業保険を推進している。図 9.9 は、アメリカの作物保険にかかるコストである。2007 年よりコストは増加傾向にあり、2012 年は歴史的な干ばつが発生し、保険料支払いが急増したため、跳ね上がっている。農家が支払う保険のプレミアムは、税金が主要財源となる助成金で賄われている。2001 年の助成金は 17 億ドルであったが、2006 年に 25 億ドル、2009 年には 2006 年の 2 倍以上である 52 億ドルに増額した。これらの補助金は、保険料の 40 から 60%を占めている。20014 年と 2015 年には、およそ 135 億ドルと 123 億ドルの予算が国家予算から拠出されたが、それぞれの年で 47 億ドルと 45 億ドルが財務省へと返却された。現行のアメリカの農業保険市場は、PPP による実施体制が取られているが、巨額の政府予算が使用されている。

9.2.4 日本の農業共済保険制度

日本は、相互組合組織による農業保険として農業災害補償制度が採用されている。この制度は、農民間の相互共済を強調しているため、農業共済保険 (NOSAI：農業共済) とよばれている。図 9.10 に農業共済の仕組みを示す。第一段階の共済では、農家が市区町村ごとで農業共済組合を設立する。農家が共済掛金を組合に納付し、災害が発生した際に被災農家に共済金を給付することで補填する。第二段階の保険では、都道府県単位で農業共済組合連合を設立し、農業共済が負う共済責任の一部を保険で担保する。保険責任に応じて連合会は組合に保険金として支払い、組合は被災農家の共済金にあてる。第三段階の再保険では、より甚大な災害の被害を分散するために、農業共済連合会の負う保険責任の一部について国が再保険する。国は保険責任に応じて、連合会に保険金を支払う。農家は、農業共済に加入するために掛金を支払う必要がある。農家の負担を軽減するためと、共済への加入を促進するため、国が農家が負担する共済掛金の 40 から 55%を負担している。また、共済事業を行う市町村に対し、事務職員の給与やその他諸経費の半分を国が負担している。日本の農業保険市場規模は、保険料ベースで約 10 億ドル程で推移している。

9.2.5 中国の農業保険

中国の農業保険は、1950年代に、国営保険会社による農業保険制度が創設された。しかし、計画経済により、保険の必要性は認識されず、農業保険制度は停止される状態となっていた。2007年になると、中国政府は保険料補助などを目的とした農業保険パイロットプロジェクトを開始した。農業保険の制度は、アメリカの制度（図9.8）と似ており、保険会社には、国営保険会社、民間保険会社や農家組合などが含まれる。保険料補助は、国営再保険会社や地方政府によって、70から80%が補助される。現在では世界第2位の農業保険大国となり、市場規模は収入保険料ベースで約50億ドルで、日本の5倍以上である。しかし、中国の農業産業の規模からすると保険加入率は低い水準にとどまっており、今後も市場成長が続けば数年以内にアメリカと同規模の市場へ成長すると予想されている。

9.2.6 アジアやアフリカの農業保険

インド

インドは、世界最大のインデックス型保険の市場を持つ。2013年時点でインデックス型保険の市場規模は約6億ドルで、収量保険は1.5億ドルとなっている。インドの農業保険制度は、1985年に国営保険会社による国営農業保険制度の発足から始まった。NPCIやMPCIなどの収量保険を取り扱ったが、当初の制度では、保険料率を保険数理上必要となる率よりも低い水準に設定していた。損害率が300%を超え、累積赤字の増大、保険金支払いの遅延など多くの問題を抱えていた。2010年からインド政府は、国営保険制度の立て直しに着手した。主に取り組んだことは、健全な保険数理に従った保険料率の採用、外国の再保険会社の参画、外資を含めた民間保険会社の参画を可能にすることなどだ。これにより、民間会社のノウハウや力を借りて、持続可能な保険制度を確立しようとした。天候インデックス保険がインドに導入されたのは2003年となっており、急激な成長をみせた。その背景として、政府による保険料補助、インデックスの簡便性、欧米の再保険会社のサポート、銀行や農村組織の既存流通チャンネルが有効にはたらいたことが要因だと考えられている。また、図4.2の世界の気象観測ステーションの分布密度より、インド国内のステーション設置密度の高さから、天候インデックス保険の利用状態の高さが伺える。今後もインドの農業保険市場は成長の加速が予想され、数年以内に約50億ドルの規模になるといわれている。

ベトナム

ベトナムでは、農林水産業が主要産業であることから、台風や洪水によって大きな被害を受けている。ベトナム政府は、2011年から2013年にかけて、米、家畜、養殖魚の分野に保険のパイロットプロジェクトを実施した。保険料の大部分を政府が負担し、大手民間再保険会社Swiss Reがサポートを行った。損害率は、米分野で15%、家畜で6%に推移し、安定的な収支を達成

したが、養殖魚は病気の発生により313%と大きな被害が発生した。養殖魚に関しては保険料率を見直し、今後はパイロットプロジェクトから全国規模への展開へと移る見込みである。

インドネシア

人口が2億人を超えるインドネシアでは、主食である米に対する自然災害リスクが深刻となっている。インドネシア政府は、2010年から日本の国際協力機構（JICA）などと協力し、米の農業保険のパイロットプロジェクトを行った。政府、JICAや国営保険会社による支援で農家の負担軽減がなされた。2018年には、日本の損保会社などが参画し、天候インデックス保険の販売が開始され、BOP（Base of the Pyramid；年収3000ドル未満で暮らしている貧困層）ビジネス支援を目指している。

タイ

タイもインドネシアと同様に米が主要農作物であり、洪水や干ばつの災害リスクに直面している。2011年からタイ政府による保険料補助が実施され、タイ農協銀行を通じて収量保険が農家に販売された。官民連携の保険制度であるが、再保険のほとんどを欧米の再保険会社へ再保険している。面積ベースで5%と着実に普及が進んでいるが、逆選択による保険金過払いが問題となっている。一方で、日本の民間損保会社が降水量をインデックスとした天候インデックス保険の販売を開始し、利用の拡大が進んでいる。

フィリピン

フィリピン政府は、保険料補助による農業保険提供を行っている。2013年11月に巨大台風Haianが甚大な被害を農村部に与え、保険による補償の必要性が高まり、加入者が急増している。フィリピンの農村は低所得者が大半を占めていることから、世界銀行などの国際機関がマイクロファイナンスによる普及を進めている。また、日本の民間損保会社が天候デリバティブである台風保険の販売を開始し、拡大展開を目指している。

ケニア

ケニアでは、農業従事者が7から8割を占めるため、干ばつによる深刻な被害が懸念されている。農薬業界最大手のSyngentaは、ケニアで現地保険会社やSwiss Reと組み、Kilimo Salamaという天候インデックス保険を販売した。この保険は、農民が種子や肥料を販売店から購入する際に保険を追加する商品となっており、他国で実施されている保険商品と比較して新規性が高い。さらに、保険契約や保険金支払いは、すべて携帯電話で行われる。アフリカでは、多くの農家が携帯電話による送金手続きを行っているため、多くの国でみられる農業銀行を介した

9.2. 各国の農業保険の導入状況と市場の特徴

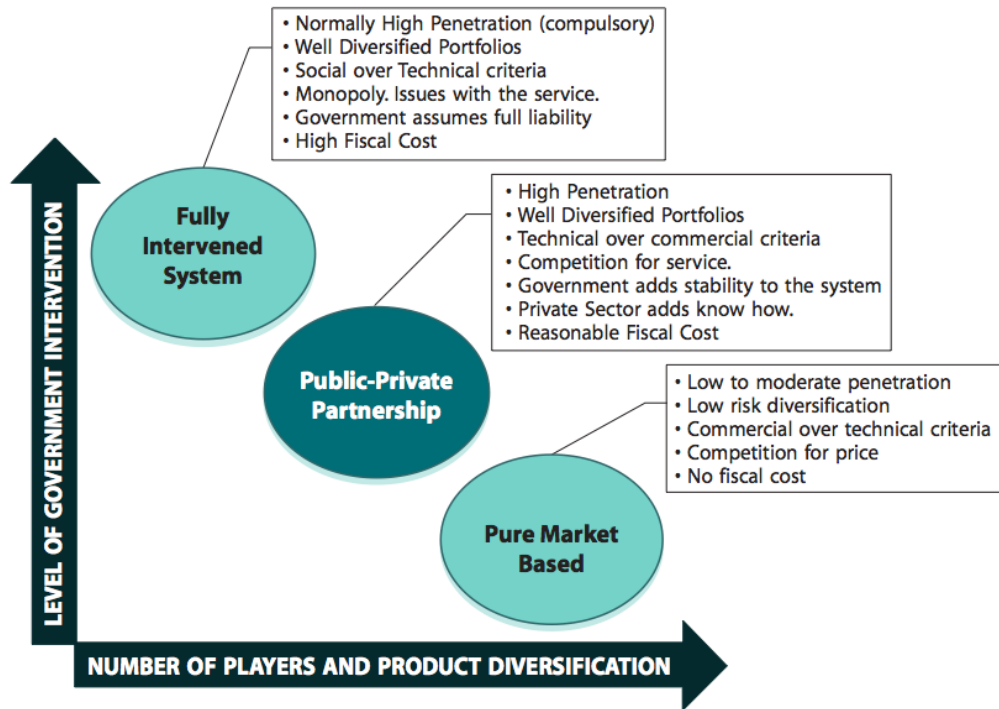
金融手続きがなされていない。今後、途上国で革新的なビジネスや制度が生まれるリバースイノベーション（イノベーションの逆流）の発生が期待できる。

表 9.1 アジア諸国の農業保険の導入状況

国	従来の査定付き保険			インデックス型保険	
	列挙危険作物保険	複合危険作物保険	作物収入保証保険	単収インデックス	天候インデックス
オーストラリア	✓				
バングラデッシュ					
中国	✓	✓			✓ ¹
北朝鮮		✓			
インド	✓			✓	✓
インドネシア		✓ ¹			✓
日本	✓	✓			
マレーシア					
モンゴル					
ネパール	✓ ¹				
ニュージーランド	✓				✓ ²
パキスタン		✓			
フィリピン		✓			✓
韓国	✓	✓ ¹			
スリランカ		✓			✓ ¹
タイ					✓
ベトナム		✓ ¹			✓ ¹
合計	7	9	0	1	8

¹ パイロットプロジェクト、もしくはローンチ待機状態

² 保険はデザインされたが、実施されていない



Source: Iturrioz, 2010

図 9.7 農業保険市場のタイプと特徴

表 9.2 アジア諸国の農業保険市場のタイプ

国	Public sector	Public-private	Pure market based
オーストラリア			✓
バングラデッシュ	✓		✓
中国		✓	
北朝鮮	✓		
インド	✓	✓	✓
インドネシア		✓	
日本		✓	
マレーシア			✓
モンゴル		✓	
ネパール	✓	✓	✓
ニュージーランド			✓
パキスタン		✓	✓
フィリピン	✓		✓
韓国		✓	
スリランカ	✓		✓
タイ			✓
ベトナム		✓	✓
合計	6	9	11

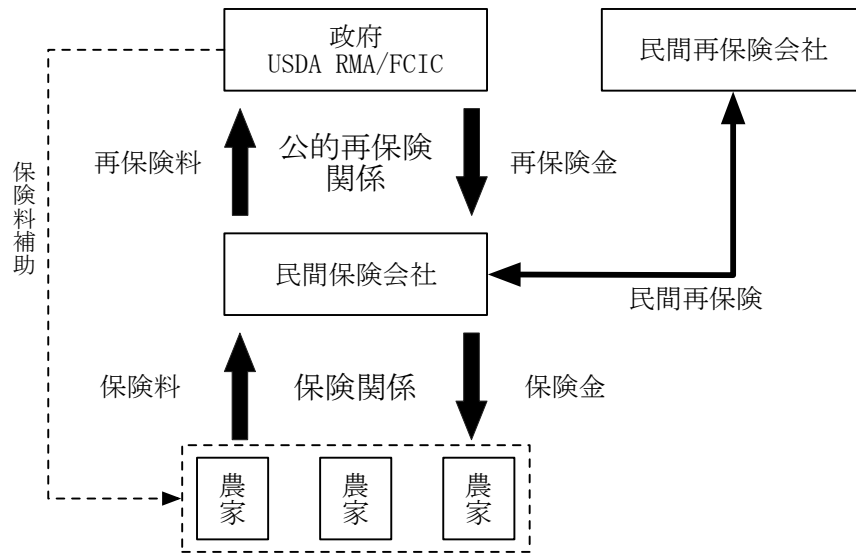


図 9.8 アメリカの農業保険制度




図 9.9 アメリカの作物保険のコスト

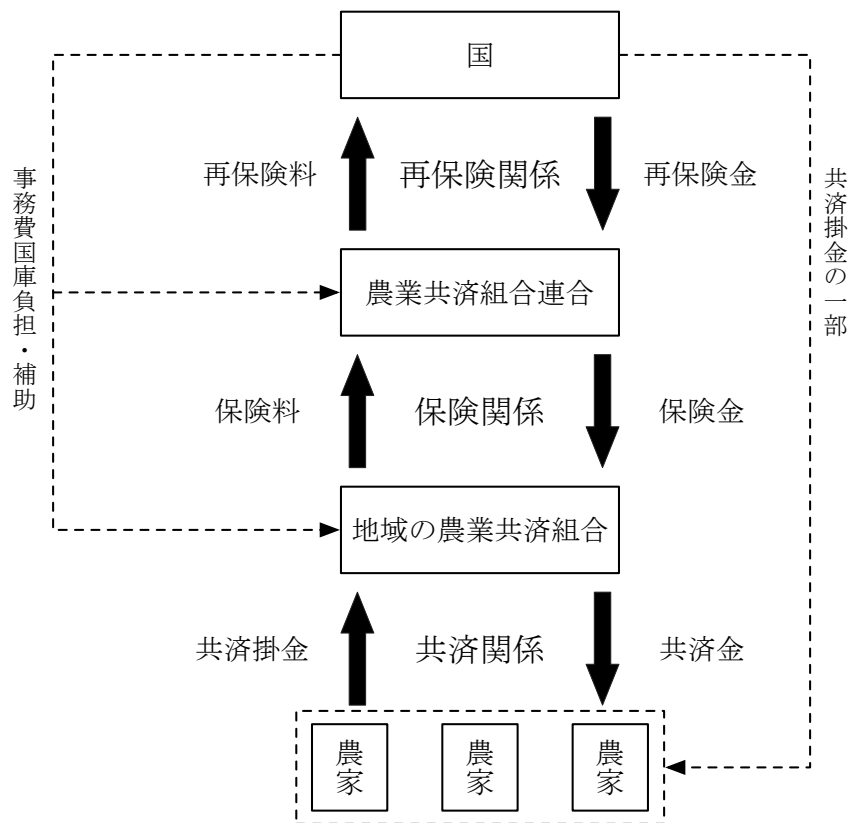


図 9.10 日本の農業共済制度

9.3 拡大する保険責任の受け入れ先

今後、農業保険の市場は、先進国だけでなく、途上国や新興国での拡大が見込まれる。市場が拡大することで懸念されるのは、リスクの許容量である。農業保険のリスク移転の一般的な流れは、第一に農家から保険会社への保険、第二に保険会社から政府もしくは民間再保険会社への再保険となっている。巨額な災害保険や地域的に偏った保険は、自己の引き受け能力を超える保険のリスクをヘッジするため再保険が利用されてきた。再保険は、保険業界全体のリスクを平準化させることで、効率的なリスク分散を行ってきた。しかし、リスク引き受け能力は限界があるため、必ずしも全ての自然災害のリスクを民間保険会社で受け入れることは難しい。民間保険会社は、災害リスクとは別に金融危機など別のリスクによって、その経営が危ぶまれるので、保険料の高騰の可能性がある。本論文では、巨大自然災害が発生した場合の対処方法として、災害保険プールと保険リンク証券を挙げる。

9.3.1 多国間災害保険プール

多国政府間で保険プールを作り、巨大自然災害が発生した際に迅速に被災国政府に保険金を支払う仕組みがある。代表例として、2007年に創設されたカリブ海諸国災害保険ファンド（Caribbean Catastrophe Risk Insurance Fund；CCRIF）がある。これは、カリブ海諸国の政府がハリケーンや地震などの巨大自然災害の被害を受けた際に迅速な補填金を受け取ることができる仕組みである。これらの国は、ハリケーンなどの被害を被る可能性はあるが、同時に発生する確率は低いいため、年間数十万から数百万ドルの保険料を過酷が拠出している。さらに欧米政府からも資金拠出を得て、巨大な保険プールを形成し、災害に備えている。

CCRIFは自然災害のリスクを分散させるものであるが、農業向けの多国間災害保険プールの作成も期待できる。ケニアなどサブサハラアフリカ地域では、干ばつによる被害を長期にわたって受けている。今後、アフリカ地域の経済発展が期待されていることから、農業に対するリスクカバーは欠かすことができない。

このような広域な地域で適用させる保険制度は、広域モニタリングが可能な衛星リモートセンシングが有用である。また、実損害の即時見積もりとして、本研究の単収推定モデルも有効であると考えられる。

9.3.2 保険リンク証券

保険リスクを資本市場の投資家に引き受けてもらう保険リスク証券というものがある。保険会社の保険引き受け能力を補うことを目的とした金融商品である。投資家には、金融リスクと異なるリスクに投資が可能になるため、投資家のポートフォリオの分散効果を高めるというメリットがある。資本市場には、多様なリスクを好む投資家が存在し、潤沢かつ流動性の高い資本によってまかなわれているため、安定した保険許容を用意することが期待されている。2016

年の第1四半期（1月から3月）では、およそ22億ドルの発行額となり、発行残高は260億ドルを超えた。発行額が最も高かったのは2014年で、一年間で88億ドルにのぼった¹。

保険リンク証券の代表例としてキャットボンド（catastrophe bond）が挙げられる。キャットボンドは、高い利率で投資家から資金を集め、予め定められた要件を満たす災害が発生すればボンド発行者が資金を受取れる仕組みである。償還期間は、3年程度で設定される。期間中に災害が発生しなければ、投資家は四半期毎に利払いを受け、満期には元利金を受け取ることができる。

保険リンク証券を契約する際に支払うリスクプレミアムは、引き受けるリスクの種類や大きさ、発生確率、リスクを引き受ける期間、債券自体の商品性や流動性、発行時の金融市況など様々な要素を反映して決定される。発行時に定められた事象の発生をトリガーとし、投資家から集められた資金の一部もしくは全てが債券発行者（保険会社など）に支払われる。トリガーの設定は4種類存在し、表9.3に示す。インデックスを採用するトリガーは、インデックス型保険と仕組みが同じであるため、債券発行者に対し、ベースリスクの問題が生じる。逆に実補填方式では、投資家にとって逆選択リスクが生じる。

本研究で開発した深層学習による単収推定モデルは、2012年に発生した大干ばつによる凶作も推定ができ、大規模災害への対応も可能となっている。ベースリスクや即時的な単収推定の観点より、本研究手法は、保険リンク証券への適用可能性が高いと考えられる。

表 9.3 保険リンク証券のトリガーの種類

トリガー	条件
実補填方式 (Indemnity)	債券発行者が予め定めた事象によって被った実損害を補填する。
モデル・ロス方式 (Model loss Index)	債券発行者が予め定めたリスクモデルに事象発生場所、風速や地表加速度など物理的パラメータを入力し、損害額を査定する。
業界インデックス方式 (Industry loss Index)	損害情報やリスク評価する会社が提供する業界全体の損害予測額を基準とする。
パラメトリック方式 (Parametric Index)	風速や地表加速などの予め定められた物理的パラメータによって発動する。

¹再保険市場の情報を提供するインターネット・サイト Artemis (http://www.artemis.bm/artemis_ils_market_reports/) のレポート Q1 2016 Catastrophe Bond & ILS Market Report を参考にした。

9.4 データの取得可能性

9.4.1 衛星の運用状況と打ち上げ計画

本論文では、無償でデータ取得が可能な衛星の運用状況や打ち上げ計画などについて主に述べる。農作物は生長することで生育ステージが変わるため、生育期間中に複数回の観測が望ましい。また、データ取得にコストがかかると、保険料が高くなる懸念されるため、無料データの利用が不可欠である。無料の衛星データは、NASAなどの欧米の宇宙機関が主に公開している。商用の有料衛星データは、一般的に無料衛星データと比較すると空間分解能が高く、撮影オーダーを出すことで、関心範囲(AOI; Area of Interest)の撮影が可能となっている。新規撮影による衛星データは、アーカイブデータよりも価格が高く、空間分解能が高ければ高いほど、高額になる。最低購入面積など購入する際の条件も設定されており、柔軟な注文が難しい場合がある。しかし、近年、アメリカなどで小型衛星を複数打ち上げ、衛星データを提供するベンチャーが現れてきており、低コストなデータ取得が可能になりつつある。

MODIS と VIIRS

Moderate Resolution Imaging Spectroradiometer (MODIS) は、NASA の Terra と Aqua 衛星に搭載された中分解能撮像分光放射計である。Terra 衛星は 1999 年、Aqua 衛星は 2002 年に打ち上げられた。バンド 1 と 2 が空間分解能 250m、バンド 3 から 7 が 500m、バンド 8 から 36 が空間分解能 1000m となっている。観測幅は 2330km となっており、Terra と Aqua の量衛星による毎日 2 回の観測が可能となっている。設計耐用年数は 6 年となっているが、10 年以上運用されている。陸域分野では、農作物の生育監視、森林伐採、洪水、火災など様々な分野で応用されている。特に長期データによる植物の炭素貯蔵量の推計などで大きな貢献を果たしている。陸域高次プロダクトは Land Processes Distributed Active Archive Center (LP DAAC) より無料で取得可能²である。

MODIS は計画年数より長く運用されているが、その後継機は Visible Infrared Imager Radiometer Suite (VIIRS) となっている。VIIRS は Suomi National Polar-orbiting Partnership (Suomi NPP) 衛星に搭載されているセンサーであり、2011 年により観測が開始された。当初は、National Polar-orbiting Operational Environmental Satellite System Preparatory Project (NPP) と名称されており、アメリカの次世代地球観測システムとして計画されていた。National Oceanic and Atmospheric Administration (NOAA) 衛星シリーズとのその代替となる Joint Polar Satellite System (JPSS) の運用機関に空白ができるのを避けるため、Suomi NPP は打ち上げられた。Suomi は、アメリカの気象学者である Verner E. Suomi の名前にちなんで名付けられた。JPSS-1 には VIIRS の搭載が計画されており、2017 年に打ち上げが計画されている。4 号機まで計画されており、2021 年、2026 年、2031 年に順次打ち上げが計画されている³。観

²<https://lpdaac.usgs.gov/>

³http://www.jpss.noaa.gov/launch_schedule.html

測波長は、可視光から長赤外線まで含んでおり、空間分解能は 745 m と 475 m となっている。EVI などの植生指数を算出する際は、青色バンドを 375 m へリサンプリングした処理を行う。VIIRS も MODIS と同様にインターネットから無料でダウンロードすることが可能である。

今後、VIIRS による長期間のデータ取得が期待できる。機械学習による単収推定モデルの構築には、長期間のデータを用いてあらゆる事象を学習させる必要がある。MODIS と VIIRS をを組み合わせた長期データの利用は有用性が高いと考えられる。しかし、MODIS と VIIRS はデータの仕様が異なるため、MODIS から VIIRS の転換期でのキャリブレーションが必要と考えられる。また、長期間のデータは保険設計上でも重要である。長期のデータをモデルに取り入れることで、数十年に一度発生するとされる想定外な災害に対し、予測可用性が得られる。

Landsat シリーズ

Landsat は 1972 年から継続して打ち上げられている衛星シリーズである。2013 年に 8 号機が打ち上げられ、運用されている。US Geological Survey (USGS) は、2008 年より USGS が取得している Landsat データの無償配布を開始した。それ以前は、Landsat 衛星データを利用するためにシーンごとに数万円の支払い購入が必要であった。

Landsat 8 のデータも無償で利用が可能である。Landsat 8 には、Operational Land Imager (OLI) と Thermal Infrared Sensor (TIRS) が搭載されている。OLI は、可視光から近赤外の観測バンドを有し、空間分解能は 30 m となっている。また、空間分解能 15m のパンクロマティックバンドも有している。TIRS は熱近赤外バンドを 2 つ有している。

Landsat 8 の回帰日数は 16 日となっており、観測幅は 185km×180 km となっている。MODIS のような高い観測頻度は得られないが、分解能が高く、非常に長期な観測データの利用が可能である。Landsat 8 の後継機である Landsat 9 は、2023 年の打ち上げが計画されている⁴。

Landsat は本研究で利用した CDL の作成に利用されている。15 から 30m の分解能を定期的 to 取得できるため、農作物の作付け状況推定や栽培作物の同定などの土地被覆分類への利用が有効であると考えられる。

Sentinel シリーズ

Sentinel は、欧州連合 (EU) とヨーロッパ宇宙機関 (European Space Agency : ESA) の共同地球観測プログラム Copernicus 計画によって開発されている地球観測衛星システムである。Copernicus では、欧州各国や ESA が有する離宮観測衛星の画像を EU の農業政策、漁業政策、環境政策や PKO 活動などに活用する方針がある。Sentinel は、その枠組みを達成するための新たな地球観測衛星であり、Sentinel-1, 2, 3, 4, 5, 6 のシリーズが計画されている。

Sentinel-1 は、Sentinel-1A が 2014 年に打ち上げられ、Sentinel-1B は 2016 年に打ち上げられた。Sentinel-1 シリーズは C バンドの合成開口レーダー (SAR : Synthetic Aperture Rader)

⁴<http://landsat.gsfc.nasa.gov/?p=10391>

を搭載した衛星であり、4つの観測モードが用意されている。SARは、マイクロ波を地表面に照射して観測を行っているため、雲や昼夜の影響を受けずに観測が可能である。SARによる複数回の撮像では、観測入射角や観測モードが変わることで地表面における電波の散乱特性が不均一になる場合がある。よって、生育期間中に日々の生長量の蓄積が影響する作物単収の推定は、SARデータの適用は難しいと考えられる。自ら撮像オーダーを出すことで撮像条件を指定することができるが、高額な金額を支払う必要がある。SARを適用した作付けパターンの判別や土地被覆分類の研究は報告されている (Zhao *et al.*, 2014; Mirzaee *et al.*, 2014)。農業保険の査定では、作物の作付け状況を広域に把握する必要があるため、作付け分類や土地被覆分類の分野でSARの利用は大いに期待できると考えられる。

Sentinel-2は、Multispectral Image (MSI) を搭載した衛星であり、Sentinel-2Aは2015年に打ち上げられ、Sentinel-2Bは2016年に打ち上げが予定されている。Sentinel-2は光学センサによる陸域観測を主に目的とした衛星である。MSIは14バンド用意されており、空間分解能は10 m, 20 m, 60 mとなっている。

Sentinel-1とSentinel-2の衛星データは、Copernicus Services Data Hub⁵で無償ダウンロードが可能である。Sentinelは運用が開始されて間もないため、データが十分にアーカイブされていない。Landsatによる併用を行うことで、観測頻度の向上が有効であると考えられる。

Planet

Planet (2016年よりPlanet Labsから社名を変更)は、アメリカのシリコンバレーにある超小型衛星の開発や運用を行なっているベンチャー企業である。2010年にNASAの元職員が創業した会社であり、従業員はおよそ500人程で、4回の投資を受けて1億5810万ドルの資金を調達している⁶。Planetでは、Dove (図9.11)という超小型衛星を100機単位で開発し、地球観測を行っている。Doveの重量はおよそ5kgとなっており、国際宇宙ステーション (International Space Station : ISS) からの軌道投入がされた。青 (420 - 530 nm), 緑 (500 - 590 nm), 赤 (610 - 700 nm) のバンドが用意されており、分解能は3 mとなっている。近赤外領域のバンドも次期衛星に追加予定である。

Planetの衛星データの利用方法は、期間契約となっており、ある一定期間に指定した範囲に撮像された衛星データを無制限に使用することが可能となっている。例えば、米国のトウモロコシが観測対象となっている場合、作付けの4月ごろから11月ごろまでを撮影期間とし、コーンベルト周辺の画像が順次撮像され、使用することができる。契約期間が満了すると、ダウンロードしたデータは削除しなければならないが、NDVIなど衛星データから算出した結果は保持することが可能である。

また、自社の衛星データの利用を促進するため、Open Californiaというプログラムを実施している。このプログラムでは、クラウドプラットフォームで、カリフォルニア州内を撮影し

⁵<https://cophub.copernicus.eu/dhus/#/home>

⁶<https://www.crunchbase.com/organization/planet-labs#/entity>

たデータをオープンライセンスによる公開が行われている。クラウドプラットフォームでは、APIが公開されており、より拡張的な利用が可能となっている。

今後、Planetのような小型衛星ベンチャーは他にも立ち上がる可能性が十分にある。小型衛星市場が大きくなることで、低コストかつ高品質なデータを利用した農業モニタリングの実現に大きく期待できる。



図 9.11 Planet の超小型衛星 Dove

9.4.2 気象データ

天候不順が農業生産に与える影響を定量的に評価する際、気象データは最も重要になるといえる。気象データの容量は、2015年時点でおおよそ45ペタバイトと推計されており、2030年には350ペタバイトまで指数関数的に増加すると考えられている(Overpeck *et al.*, 2011)。その背景は、将来の温暖化などの気候変動の解明やより厳密な意思決定を実現することが必要となり、気候学者内だけでなく、あらゆる分野でのデータ共有が促進されることがパラダイムとして考えられている。今後、衛星やレーダーから取得されたデータや気候モデルによってシミュレーションされた気象データが爆発的に増え、多くの分野で利用されることが期待される。

本論文では、衛星から取得可能な気象プロダクトを挙げ、作物単収モデルの構築や農業保険への利用の有用性について述べる。

光合成有効放射量プロダクト

光合成有効放射量 (PAR : Photosynthetically Active Radiation) は、地表面に到達する波長400 nmから700 nmまでの太陽光の量である。高等植物の光合成には、400 nmから700 nm

の波長帯の太陽光が有効とされ、光合成生産の見積もりに PAR は重要なデータとなっており、単収推定モデルの構築に有効な入力データであると考えられる。MODIS から PAR を推定するアルゴリズムはいくつも提案されており、地上観測された PAR と比較することで高い推定精度が確認されている (Liang *et al.*, 2006; Nasahara, 2009)。PAR の推定にはセンサーの仕様に依存しないため、VIIRS を用いた長期推定も可能である (Liang *et al.*, 2007)。MODIS による PAR プロダクトは、JAXA Satellite Monitoring for Environmental Studies (JASMES) ⁷でダウンロードできる。

降水量プロダクト

全球の降水量プロダクトとして、Global Satellite Mapping of Precipitation (GSMaP) が JAXA より提供されている。GSMaP は、静止気象衛星や複数衛星に搭載されたマイクロ波放射計や降水レーダを用いて、準リアルタイムの降水量マップである。観測から約 4 時間後に空間分解能 0.1° で、1 時間毎の全球降雨マップを公開されている⁸。災害や農業などの用途で幅広く利用されており、タイの稲作向けの天候インデックス保険のパイロットプロジェクトでも活用された。作物は、干ばつによって成長が強く阻害されて減収のリスクがあるため、降水量は単収推定モデルの重要なモデルと考えられる。

土壌水分プロダクト

土壌水分は、作物生長に大きなインパクトを与える情報であり、生育状況を把握するために最も重要な情報である。USDA では一週間ごとにアメリカ全土の作物生育状況と天候状況を報告する Weekly Weather and Crop Bulletin⁹があり、併せて、気象、水理や土壌条件をもとに干ばつモニタリングが行われている¹⁰。土壌水分自体は、アメリカの 40 州に 200 カ所で設置されているに設置されている観測ステーションネットワーク、Soil Climate Analysis Network (SCAN) で観測されている (Schaefer, Cosh & Jackson, 2007)。しかし、土壌観測ステーションのメンテナンスはコストがかかり、地上観測では網羅的な観測が不可能であることから、衛星による観測が必要となる (Yang, Mueller & Crow, 2013)。

Soil Moisture Active Passive (SMAP) は、2015 年に NASA によって打ち上げられた地球観測衛星で、L バンドのレーダーとマイクロ放射計を搭載している。全球の土壌水分をモニタリングするため、最短で 24 時間後に土壌水分プロダクトを公開する予定だったが、打ち上げ後の 6 月に、搭載されているレーダーの停止が確認された¹¹。現在はマイクロ波放射計のデータのみで作成された土壌水分プロダクトが NASA National Snow and Ice Data Center Distributed

⁷http://kuroshio.eorc.jaxa.jp/JASMES/index_j.html

⁸<http://www.eorc.jaxa.jp/GSMaP/>

⁹<http://www.usda.gov/oce/weather/>

¹⁰<http://droughtmonitor.unl.edu/>

¹¹<http://smap.jpl.nasa.gov/news/1247/>

Active Archive Center (NSIDC DAAC) で取得可能となっている。運用が停止した SMAP のレーダーの代替として、SMAP の軌道上に近い Sentinel-1 の利用が検討されている¹²。

9.4.3 収量データ

機械学習で単収推定モデルを構築する上で、作物の収量データは欠かせない。アメリカでは、USDA NASS によって郡ごとの単収の統計データが公開されている。全世界の統計データは、FAOSTAT¹³で公開されているが、国レベルのデータしか扱われていない。より詳細なレベルでデータを取得するためには、各国で管理されている統計データに直接アクセスする必要がある。

¹²<http://spacenews.com/nasa-focused-on-sentinel-as-replacement-for-smap-radar/>

¹³<http://faostat3.fao.org/home/E>

9.5 今後途上国で導入される農業保険

本章でとりまとめた農業保険やデータに関して、これからの農業保険について以下に述べる。

9.5.1 今後の農業保険市場の見通し

現在の農業保険市場は、保険料ベースでおよそ3兆円規模と想定され、その半分をアメリカとカナダによる北米で占めている。アメリカでの農業保険普及率は、面積ベースで9割を超えており、今後は、世界で頻発する自然災害の多くを占めるアジア地域、特に中国やインドでの成長が期待される。また、深刻な干ばつに悩まされているサブサハラアフリカの地域での拡大も予想される。さらにブラジルなどの南米やロシアやウクライナなどの国々は、アメリカに次ぐ世界の食糧生産国として世界から注目されている。農業保険の普及率は低水準となっているが、国策として農業保険の普及促進が掲げられており、世界の農業保険市場の拡大に寄与すると考えられる。アジアやアフリカの農業保険市場は、まだ導入期となっており、先進国からの技術供与や制度の見直しが必要となる。

途上国や新興国で適用されている農業保険は、減取リスクをターゲットにした収量保険やインデックス保険が多い。一方でアメリカで契約される農業保険は、収入保険が主となっている。この違いは、作物市場の特性が強く関係していると考えられる。アメリカは世界最大の穀物輸出国であり、さらに自由経済に則した国際的な作物市場を有していることから、価格の変動性が非常に高い。価格の変動性は、農家の収益に直接的に影響を及ぼすため、アメリカでは価格リスクを保証する保険のニーズが高くなる。今後、ブラジルのように、アメリカに代わる食糧生産を支える国が台頭することで、生産国の作物市場が拡大し、価格リスクをカバーする収入保険のニーズはますます高まる。

今後はロシアやウクライナ、南米などの大規模な穀倉地帯を有する新興国とアジアやアフリカなど小規模な農家が多い途上国のそれぞれで農業保険導入が促進されると考えられる。いずれにせよ、政府と外国保険企業によるサポートは必要となるが、提供される保険商品は各国の農業事情に則したものを適用することが予想される。

9.5.2 今後開発される新しい農業保険

農業保険を国の政策として促進する際、多くの課題が障壁となる。その代表的なものが「ベシスリスク」と「コスト」である。これらの課題を解決する際、先進国で適用された手法ではなく、新しい技術や方法を取り入れた保険の仕組みづくりが期待できる。

ベシスリスクを改善するためには、観測データの空間的分解能を向上させるために観測ステーションの増強が有効であるが、インフラ投資や整備にコストがかかるため現実的な方法とはいえない。そこで衛星で広域観測したデータが有効となる。今後は、民間の小型衛星も含め、運用される衛星は増加し、衛星利用に要するコストも低下することから、農業保険適用に向けた技術開発が活発になると予想される。

また、農業保険の損害査定を行う仕組みも変わることが予想される。損害査定を行う際、保険会社と農家との間で客観的かつ公正な判断を下すアジャスターというものが存在する。このアジャスターが上手く機能しないと、農業保険は機能せず、農業保険の信頼性は失われてしまう。アジャスターには高いスキルと十分な経験を要することから、育成するために長い期間とコスト、それを支える制度が必要となる。このようなソフト政策は、技術の導入で代替が可能な場合、途上国では適用されない可能性がある。その例がアフリカで発生した携帯電話による契約や送金方法となるリバースイノベーションである。携帯電話を活用することで、保険に関わる手続きを簡略化し、コストを低下させるとともに農業保険の浸透に貢献した。

本研究で開発した深層学習による単収推定手法は、ベースリスクの軽減だけではなく、従来の保険の仕組みを変える可能性がある。単収推定モデルは、作物の単収自体をインデックス化し、アジャスターが担当する一部の作業が自動化され、農業保険の仕組みを動かす新しい装置を担うことが考えられる。あらゆる制度が未発達な途上国や新興国では、このような技術による代替によって仕組みの簡略化が発生すると考えられる。

今後、途上国や新興国では、農業保険の普及率を高めるため、単なる保険料補助だけではなく、新しい導入方法の提案がなされると考えられる。ケニアで販売された Kilimo Salama では、農薬、種子や肥料などの追加商品として保険が販売された。先進国と比較すると、途上国の農業はまだ非効率であり、改善の余地が大いにあるため、農業資材の投入や栽培サポート情報の提供サービスが農家にとっての便益性が高い。農業保険を単一で販売するのではなく、それらの付加的なものとして取り扱われ、導入されることが考えられる。また、農家の生産性が向上することで、保険会社の支払いリスクが低減し、持続的な農業保険市場の構築に貢献できる。

9.5.3 大規模災害の対策となる農業保険

農業保険市場の成長や気候変動による自然災害の増加と相高まり、より大きな保証責任の受け皿が必要となる。大規模な災害に対し、保険会社は再保険することでリスクを分散させているが、業界全体のリスク許容には上限が存在する。想定外になるほどの大きな災害リスクを保証するため、保険プールと保険リンク証券が有効である。これらの保険にも、通常の保険のベースリスク、逆選択やコストなどといった課題が存在し、本研究で提案した手法が有効的に活用できると考えられる。

第10章 まとめと今後の展望

10.1 各章のまとめ

以下に各章の成果についてまとめる。

第1章：はじめに

本章では、逼迫する将来の食料需給の安定化に寄与する農業保険市場の成長と必要性について述べ、従来型とインデックス型保険の特徴を比較することで、普及促進に向けた農業保険の課題について挙げた。従来型の保険は、査定による保険金支払いがなされるため、逆選択やモラルハザードといった農家に関わる操作不可能なリスクが問題になることから、インデックス型保険の適用が望ましいということを検討した。インデックス型保険には、「ベシスリスク」という実損害額と補償額の乖離リスクが最大の課題とされており、解決のためにはデータ整備のインフラ投資によるコスト増大というトレードオフの問題が掲げられた。そこで本研究では、ベシスリスクとコストを農業保険の主な課題とし、これらを改善するための衛星データと機械学習を用いた単収推定手法の開発に取り組むとともに、本手法を適用した農業保険の開発を提案した。対象地は、農業保険市場、世界最大のアメリカを選定し、食料安全保障上、重要となるトウモロコシを対象作物とし、アメリカでベストケースを作成することで、他の地域への導入可能性について検討することとした。

第2章：気象データと収量の相関分析

本章では、第1章で提案した単収推定モデルの比較として、気象データと単収の相関分析による天候インデックスの有効性について検証した。再解析データ ERA-Interim と全球高分解能気象データ CRU の2つの空間分解能が異なる気象データと単収との相関係数を算出することで、気象データの空間分解能がベシスリスク軽減に与える影響について評価した。

分析には30年分のデータを用いるため、技術改良によるトウモロコシ単収の上昇トレンドを考慮する必要であることから、トウモロコシの作柄を定量的に示す作況指数を USDA から取得した単収データから算出した。また、気象データから暖かさ指数や露点差など作物単収との高い相関があると考えられる特徴量の形成や、月ごとの標準化による正規化を行った。処理された ERA-Interim と CRU のそれぞれを、州レベルおよび群レベルの作況指数との相関係数を計算した。

結果、気温や大気の乾燥と関連する蒸発散や露点差は、コーンベルト周辺地域において、7月に負の相関関係が得られた。逆に降水量は、同様の地域で正の相関関係が確認された。さらに、群レベルの相関結果をマッピングすることで、州内でも地域ごとの詳細な気象データと作柄の相関関係が得られた。しかし、コーンベルト以外の州では、相関関係が得られなかった。

以上の結果より、(1) 暖かさ指数や露点差など特徴量の形成は、トウモロコシの作柄とより強い相関関係が得られた、(2) 州レベルから群レベルへと分析を行うことで、空間的に詳細な相関関係が確認できた、(3) トウモロコシの主要産地以外の地域では気象データと作柄の相関関係は得られなかった、という知見が得られた。

実際に天候インデックス保険を作成する際、各地域での天候インデックスの作成が必要となるが、その方法は地域によって異なるため、天候インデックスの煩雑なオーダーメイドが必要となる。ベースリスクを軽減するより一般的な手法を確立するためには、天候インデックス保険には課題があると考えられる。

第3章：天候インデックス保険の開発

第2章の気象データと相関分析の結果を利用して、天候インデックス保険を開発し、農家の収入保証性を定量的に評価した。2012年のような歴史的な大干ばつが発生した年では、多額の保険金支払が実行され、農家の収入を赤字から黒字へ転換することが可能となった。しかし、収入に応じた支払がなされず、利益の格差が拡大することとなり、大きなベースリスクが存在することが確認された。天候インデックス保険を開発するためには、単収の減収と強い相関関係にあるインデックスを形成する必要があるが、地域によって気象パラメータと単収の相関関係は異なる。よって、地域ごとにインデックスを設計する必要があるため、天候インデックス保険の開発には非常に煩雑な作業が必要となる。また、単収と完璧な相関関係を有するインデックスの形成は難題であることから、ベースリスクを低減した天候インデックス保険の開発はきわめて困難である。

第4章：衛星データと深層学習による単収推定モデルの開発

本章では、第2章の分析結果から得られた天候インデックスの課題を解決するため、衛星データと深層学習による群レベルのトウモロコシ単収推定モデルの開発に取り組んだ。

入力データには、アメリカを対象とする1 km空間分解能の気象データ Daymet と MODIS から推定した EVI を用いた。EVI は、雲の影響によってノイズが含まれるため、Wavelet 変換によるスムージング処理を施した。そして、Daymet と EVI を日別と5日間積算の2つのデータセットを用意し、標準化による正規化をそれぞれ行った。また、トウモロコシ畑の情報だけを得るため、USDA から提供される詳細な土地被覆データ CDL を用いて、トウモロコシ畑上で入力データをマスキングし、郡ごとに平均値を算出し集計した。

深層学習には、隠れ層6層のフィードフォワード型のニューラルネットワーク、DNN を用いた。さらに、深層学習の性能を比較するため、Autoencoder と SVM による推定モデルの学習

を行った。学習の際は、全てのデータ標本群の8割を学習に用いて、残り2割を評価に用いた。DNNとAutoencoderの学習方法はミニバッチ学習法、SVMにはグリッドサーチを活用した。

評価結果では、5日間積算の入力データセットで学習したSVMによる推定結果が精度が最も高かった ($R^2 = 0.792$, RMSE = 17.7)。しかし、より高次元な日別の入力データセットで学習すると推定精度が下がった ($R^2 = 0.727$, RMSE = 20.4)。Autoencoderは、SVMと逆の結果が得られ、5日間積算より日別データセットの方が精度が高かった (日別データセット: $R^2 = 0.758$, RMSE = 19.0, 5日間積算: $R^2 = 0.700$, RMSE = 21.3)。DNNは、日別と5日間積算のデータセットで同じ推定精度となった (日別データセット: $R^2 = 0.773$, RMSE = 18.5, 5日間積算: $R^2 = 0.780$, RMSE = 18.2)。よって、DNNやAutoencoderによる単収推定モデルは、より高次元な入力データセットでも高い精度で単収することが確認された。

今後、モデルの推定精度を高めるため、土壌水分などのデータを入力データセットに取り入れた場合、より高次元なデータになることから、深層学習が有用であることがわかった。また、全米の群レベルのトウモロコシ単収を一括して推定した手法は、本研究が初となる試みであった。

第5章：深層学習による単収推定モデルの性能評価について

本章では、「適用範囲の限定」、「汎化性の評価」、「衛星データの有効性」の3つの観点で深層学習のモデル学習の性能を検証した。第4章では、全米のトウモロコシ単収を一括で推定したが、Heartland地方というトウモロコシ栽培の主要地域でモデルを深層学習で学習させた。結果、推定精度が全米の場合よりも向上した。しかし、範囲を限定しすぎると学習データの十分なサンプル数が得られず、推定モデルの学習が不十分となる可能性がある。汎化性については、leave-one-out cross validation (LOOCV)の方法を用いて時間方向に評価した。2008年から2013年までの6年間のデータのうち、各年を学習用データセットから取り除き、5年分のデータで学習させた単収推定モデルを検証年のデータで評価した。結果、有意な推定精度は得られなかった。汎化性を向上させるためには、より長期間のデータ利用が必要と考えられる。衛星データの有効性では、MODISから推定したEVIを入力データから取り除いた場合とEVIのみを入力データとして単収推定モデルを学習し、推定精度を評価した。結果、EVIと気象データを組み合わせた第4章の方法が最も高精度となった。

第6章：トウモロコシ単収のダウンスケーリング手法の開発

本章では、第4章で構築した、衛星データと深層学習による郡レベルのトウモロコシ単収推定モデルのダウンスケーリングを行った。コーンベルト周辺の郡はおよそ50kmの大きさがあり、郡内のトウモロコシの生産力は均一でないことから、郡レベルの単収推定モデルでもベシリスクが潜在すると考えられる。

第4章で学習したDNNを1kmの入力データセットを入力し、CDLのトウモロコシ畑上で単収を推定することで、単収のダウンスケーリングを行った。単収のダウンスケーリング結果

を郡ごとで平均による集計をし、USDA の郡レベル単収と比較して、本手法のダウンスケーリングを評価した。2008 年の結果は $R^2 = 0.83$, $RMSE = 14.84$ となった。トウモロコシの収穫面積の小さい郡では、ダウンスケーリング単収の結果は過少推定の傾向にあった。

ダウンスケーリングのマッピングを確認すると、コーンベルト地域において、郡レベルの単収分布より詳細な分布を表現していることが確認できた。

第 7 章：単収推定モデルによる単収推定保険の開発

本章では、第 6 章で開発したダウンスケーリング手法を用いて、アメリカの収入保険を参考にした農業保険の保険金を算出した。

農家が保険によって利益を確保できたかを確認するため、トウモロコシによる営業利益を算出し、保険料を加算した利益を確認した。営業利益、保険料、利益をそれぞれマッピングすることで、深刻な干ばつで営業利益に損失を出していた地域でも、保険料によって赤字から黒字に転換し、利益を確保できたことが確認できた。また、豊作による価格下落で損失を被った豊作貧乏の場合でも、保険料によって損失を補填できることも確認できた。

また、農業の支払いリスクを確認するため、2008 年から 2013 年の 6 年間の保険料を計算し、分散を求めた。コーンベルト周辺地域では、一様に 400 ドル程となったが、生産規模が小さい地域ではおよそ 1000 ドルとなった。生産規模の小さい地域では、ダウンスケーリング単収は、過少推定の傾向があるため、過払いが発生する可能性があることがわかった。

単収推定保険は、市場価格のリスクもカバーすることができるため、従来の収量保険や天候インデックスより、農家のニーズに対応した保険であるといえる。そして、単収推定モデルを適用することで、査定に要するコストを削減し、収穫時の早期の保険料算出を行うことが可能となり、これまでの農業保険の課題解決に資するものとする。

10.1.1 第 8 章：天候インデックス保険と単収推定保険の比較

本章では、第 3 章と第 7 章で開発した天候インデックス保険および単収推定保険の収入保証性を定量的に比較評価した。結果、衛星データと深層学習による単収推定モデルを適用した単収推定保険は、天候インデックス保険に比較して損害に対応した正確な保険金支払いが可能となっていることが示された。

第 9 章：途上国及び新興国への農業保険導入のための考察

本章では、今後、途上国や新興国で導入される農業保険についての考察を行った。アジアは、産業の大部分を農業が占めているため、世界で頻発する自然災害の多くが発生していることから、自然災害が農業に与えるインパクトが大きい。よって、今後、アジアでの農業保険のニーズは高まり、市場の成長が見込まれる。また、アフリカでも農業保険のニーズはあり、新しい技術を取り入れた保険の導入がされている。

今後は、MODISの後継機であるVIIRSが次世代地球観測衛星に搭載され、継続して運用されるため、長期的なデータ取得が可能となる。持続可能な単収推定モデルによる農業保険の開発に期待できる。また、近年、小型地球観測衛星を開発・運用するベンチャー企業が進出してきており、農業保険に必要なデータの取得に要するコストが軽減されることが予想される。

また、より大規模な自然災害のリスク引き受け先として、多国間保険プールの検討と保険リンク証券の市場が拡大している。これらの保険でも、逆選択やベースリスクといった問題が課題となっているため、本研究で開発した単収推定モデルの適用の有効性に期待できる。

10.2 今後の展望

小規模な作物生産地での単収モデルの高精度化

本研究で開発した深層学習による単収推定モデルは、高い精度でトウモロコシ単収を全米で推定することが可能となったが、生産規模の小さい地域では、過少推定の結果にあった。本手法では、気象データと衛星の植生指数のみを深層学習の入力データとしているため、作物の品種や各農地の栽培生産性に関わる情報（施肥や灌漑など）は考慮されていない。作物の主要生産地以外の地域でも高精度に単収を推定するため、より多くの情報を入力する必要があると考えられる。

例えば、SMAPによる土壌水分プロダクトは有効な追加入力データだと考えられる。作物生長は、土壌の水分状況に敏感であることから、灌漑設備の整備状況は各農地の作物単収に大きな影響を及ぼすと考えられる。アメリカでは、地下水を汲み上げることで灌漑を実施しているので、SMAPの土壌水分プロダクトは農地の灌漑状況を特徴量として深層学習に与えることが期待できる。

さらに、作物の栽培環境は近傍の地域において空間相関が強いことが想定される。よって、特徴量に空間相関を表す隣接行列などを特徴量として与えることが有効であると考えられる。隣接行列は、空間統計の分野において空間的な自己相関を有する事象をモデリングする際に利用される (Getis & Aldstadt, 2010)。CDLのような土地被覆データから隣接行列を作成し、入力データとして適用することで作物栽培地の周囲の特徴量をモデルに与えることが期待できる。

また、今後は小型衛星による空間分解能 5 m 級の衛星データを低コストで取得可能になることが予想される。VIIRSなどの空間分解能が低い衛星データと高空間分解能の衛星データを組み合わせたデータ融合の技術を取り入れることで、単収のダウンスケーリングの精度向上が期待できる。

ニューラルネットワーク改良による推定精度向上

本研究では、SVM、隠れ 6 層の DNN や autoencoder を用いて単収推定モデルを構築した。ニューラルネットワークを学習モデルに適用する際、ハイパーパラメータ（学習係数、層の段数、ニューロンの数、dropout, batch size など）の最適な調整が重要となる。より高精度に単収を推定するため、ハイパーパラメータのキャリブレーションを自動的に行う手法を取り入れることが有効であると考えられる。加えて、本研究では気象メッシュデータや衛星データなどの地理空間情報を活用している。作物栽培は、品種や栽培環境が近傍地域との自己相関が強いことが想定される。よって、郡単位での平均集計ではなく、畳み込みニューラルネットワークを適用した手法が新たな特徴量形成方法として期待できる。

長期間データを用いた汎化性向上に向けた単収推定モデル構築

本研究では、CDLの取得可能状況によって、2008年から2013年までの6年間という短期間のデータを用いて単収推定モデルを構築した。機械学習や保険設計では、長期間のデータを取り入れることで、発生頻度の低い大規模災害を考慮する必要がある。長期間のデータを学習データセットに取り入れることで、あらゆる気象条件に対応した単収推定モデルの構築に寄与することが可能となり、モデルの汎化性の向上に期待できる。今後もCDLは継続して配布されるため、VIIRSなどのデータを組み合わせて長期間のデータを収集し、幅広い自然災害に備える必要がある。

保険金支払いの仕組み改善

本研究で提案した単収推定保険は、従来の天候インデックス保険よりベースリスクを低減したリスク補填を可能とした。しかし、保険金の過払いが大きな課題として考えられるため、保険収支が均衡した保険設計を行う必要がある。本研究の目的である、ベースリスクの低減は、単収推定の精度向上で達成できるが、適切な保険設計は実務に大きく依存することが考えられる。よって、保険事業会社へのヒアリングなどを行い、適切な保険設計を調査する必要がある。

本手法の他国導入のためのテストケース

本研究では、アメリカをモデルケースとして、衛星データと深層学習によって単収推定モデルを構築し、農業保険へ適用し、その有用性を示した。アメリカでは、農業に関わる統計データが最も整備されているため、高水準な手法の確立が可能である。今後、農業保険のニーズがますます高まる途上国や新興国に対し、本研究で作成した手法の流れを適用することで、その可用性を検証する必要がある。

途上国では気象観測ステーションの設置数が乏しいことが懸念されるため、衛星データの有用性がますます高まる。衛星データより、PARや降水量などの気象パラメータの推定が可能となっているため、地上の気象データの代替として利用が期待される。今後は、あらゆるソースのデータを複合的に利用し、単収推定モデル構築の手法確立の必要性が高まると考えられる。

付録A Heartland地方のトウモロコシ価格及び栽培に要するコスト




図 A.1 Heartland 地方におけるトウモロコシの価格および単収




図 A.2 Heartland 地方におけるトウモロコシ栽培に要するコスト

付録B 機械学習による単収推定モデルの汎化性評価




図 B.1 2008 年を学習データセットから外した単収推定結果




図 B.2 2009 年を学習データセットから外した単収推定結果




図 B.3 2010 年を学習データセットから外した単収推定結果

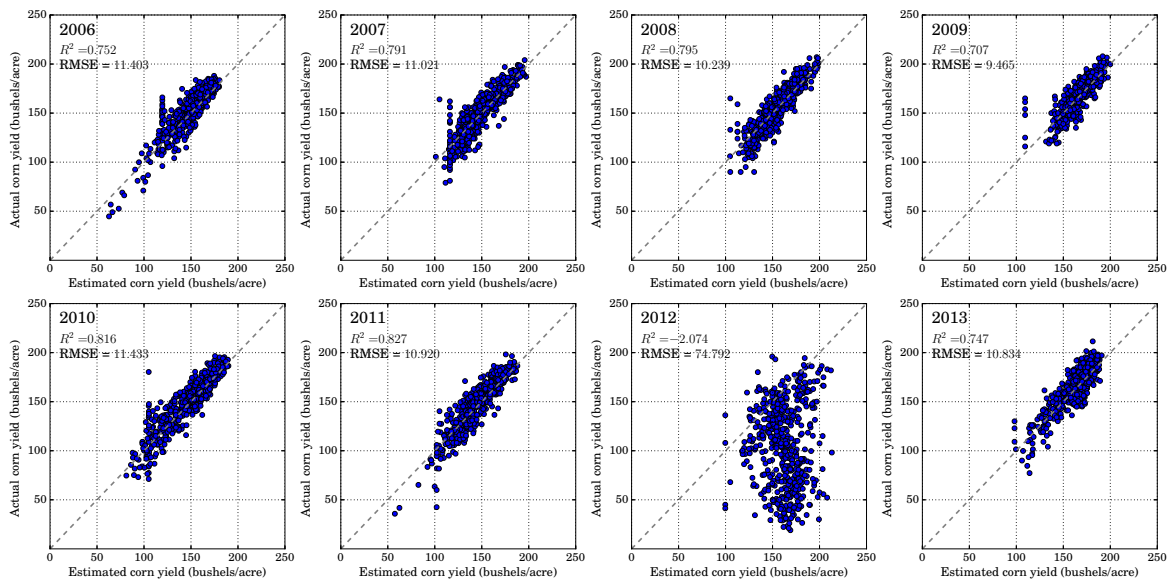


図 B.4 2012 年を学習データセットから外した単収推定結果




図 B.5 2013 年を学習データセットから外した単収推定結果

参考文献

- [1] AGGARWAL, RAJEEV & S RATHORE, ‘Noise Reduction of Speech Signal using Wavelet Transform with Modified Universal Threshold..’ *International Journal of Computer Applications*, **20** (5), pp. 14–19, 2011.
- [2] COLLIER, BENJAMIN, JERRY SKEES, & BARRY BARNETT, ‘Weather Index Insurance and Climate Change: Opportunities and Challenges in Lower Income Countries.’ *The Geneva Papers on Risk and Insurance Issues and Practice*, **34** (3), pp. 401–424, 2009.
- [3] CONRADT, SARAH, RAUSHAN BOKUSHEVA, ROBERT FINGER, & TALGAT KUS-SAIYNOV, ‘Yield trend estimation in the presence of farm heterogeneity and non-linear technological change.’ *Quarterly Journal of International Agriculture*, **53** (2), pp. 121–140, 2014.
- [4] DENTE, L, G SATALINO, F MATTIA, & M RINALDI, ‘Assimilation of leaf area index derived from ASAR and MERIS data into CERES-Wheat model to map wheat yield.’ *Remote Sensing of Environment*, **112** (4), pp. 1395–1407, apr, 2008.
- [5] DONOHO, D L, ‘De-noising by Soft-thresholding.’ *IEEE Trans. Inf. Theor.*, **41** (3), pp. 613–627, 1995.
- [6] DRUMMOND, S T, K A SUDDUTH, A JOSHI, S J BIRRELL, & N R KITCHEN, ‘Statistical and neural methods for site-specific yield prediction.’ *Transactions of the Asae*, **46** (1), pp. 5–14, 2003.
- [7] FANG, HONGLIANG, SHUNLIN LIANG, & GERRIT HOOGENBOOM, ‘Integration of MODIS LAI and vegetation index products with the CSMCERESMaize model for corn yield estimation.’ *International Journal of Remote Sensing*, **32** (4), pp. 1039–1065, 2011.
- [8] FAO, ‘World agriculture: towards 2030/2050.’ Technical Report June, Food and Agriculture Organization of the United Nations, p. 78, 2006.
- [9] ———, ‘FAO’s Director-General on How to Feed the World in 2050.’ *Population and Development Review*, **35** (4), pp. 837–839, 2009.

-
- [10] ———, ‘Agricultural insurance in Asia and the Pacific region.’ Technical report, FAO, p. 225, 2011.
- [11] ———, ‘Impact of Natural Hazards and Disasters on Agriculture and Food Security and Nutrition.’ Technical Report May, FAO, pp. 1–16, 2015a.
- [12] ———, ‘The impact of disasters on agriculture and food security.’ Technical report, FAO, 2015b.
- [13] FRIEDL, MARK A., DAMIEN SULLA-MENASHE, BIN TAN, ANNEMARIE SCHNEIDER, NAVIN RAMANKUTTY, ADAM SIBLEY, & XIAOMAN HUANG, ‘MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets.’ *Remote Sensing of Environment*, **114** (1), pp. 168–182, jan, 2010.
- [14] GALFORD, GILLIAN L., JOHN F. MUSTARD, JERRY MELILLO, ALINE GENDRIN, CARLOS C. CERRI, & CARLOS E.P. CERRI, ‘Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil.’ *Remote Sensing of Environment*, **112** (2), pp. 576–587, feb, 2008.
- [15] GETIS, ARTHUR & JARED ALDSTADT, ‘Constructing the Spatial Weights Matrix Using a Local Statistic.’ In Anselin, Luc & J Sergio Rey (eds.) *Perspectives on Spatial Data Analysis*. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 147–163, 2010.
- [16] JIANG, D, X YANG, N CLINTON, & N WANG, ‘An artificial neural network model for estimating crop yields using remotely sensed information.’ *International Journal of Remote Sensing*, **25** (9), pp. 1723–1732, 2004.
- [17] JONES, J.W, G HOOGENBOOM, C.H PORTER, K.J BOOTE, W.D BATCHELOR, L.A HUNT, P.W WILKENS, U SINGH, A.J GIJSMAN, & J.T RITCHIE, ‘The DSSAT cropping system model.’ *European Journal of Agronomy*, **18** (3-4), pp. 235–265, jan, 2003.
- [18] JOSHI, NEHA, MATTHIAS BAUMANN, ANDREA EHAMMER, RASMUS FENSHOLT, KENNETH GROGAN, PATRICK HOSTERT, MARTIN JEPSEN, TOBIAS KUEMMERLE, PATRICK MEYFROIDT, EDWARD MITCHARD, JOHANNES REICHE, CASEY RYAN, & BJÖRN WASKE, ‘A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring.’ *Remote Sensing*, **8** (1), p. 70, jan, 2016.
- [19] KHAIRUNNIZA-BEJO, SITI, SAMIHAH MUSTAFFHA, WAN ISHAK, & WAN ISMAIL, ‘Application of Artificial Neural Network in Predicting Crop Yield: A Review.’ *Journal of Food Science and Engineering*, **4**, pp. 1–9, 2014.

-
- [20] KINGMA, DIEDERIK & JIMMY BA, ‘Adam: A Method for Stochastic Optimization.’ In *International Conference on Learning Representations*. dec, 2014.
- [21] KIRA, TATSUO, 「On the altitudinal arrangement of climatic zones in Japan—a contribution to the rational land utilization in cool highlands」, 『Agricultural Science of the North Temperate Region』, **2**, 143–173 頁, 1948 年.
- [22] LI, AINONG, SHUNLIN LIANG, ANGSHEG WANG, & JUN QIN, ‘Estimating Crop Yield from Multi-temporal Satellite Data Using Multivariate Regression and Neural Network Techniques.’ *Photogrammetric Engineering & Remote Sensing*, **73** (10), pp. 1149–1157, 2007.
- [23] LIANG, S, T ZHENG, D WANG, K WANG, R LIU, S C TSAY, S RUNNING, & J TOWNSHEND, ‘Mapping high-resolution incident photosynthetically active radiation over land from polar-orbiting and geostationary satellite data.’ *Photogrammetric Engineering and Remote Sensing*, **73**, pp. 1085–1089, 2007.
- [24] LIANG, SHUNLIN, TAO ZHENG, RONGGAO LIU, HONGLIANG FANG, SI-CHEE TSAY, & STEVEN RUNNING, ‘Estimation of incident photosynthetically active radiation from Moderate Resolution Imaging Spectrometer data.’ *Journal of Geophysical Research*, **111** (D15), pp. 1–13, 2006.
- [25] MIRZAEI, S., M. MOTAGH, H. AREFI, & M. NOORYAZDAN, ‘Classification of agricultural fields using time series of dual polarimetry TerraSAR-X images.’ *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, **40** (2W3), pp. 191–196, 2014.
- [26] MONTEITH, J L, ‘Solar radiation and productivity in tropical ecosystems.’ *Journal of Applied Ecology*, **9** (3), pp. 747–766, 1972.
- [27] MOUNTRAKIS, GIORGOS, JUNGHO IM, & CAESAR OGOLE, ‘Support vector machines in remote sensing: A review.’ *ISPRS Journal of Photogrammetry and Remote Sensing*, **66** (3), pp. 247–259, 2011.
- [28] NASAHARA, KENLO NISHIDA, ‘Simple Algorithm for Estimation of Photosynthetically Active Radiation (PAR) Using Satellite Data.’ *Sola*, **5**, pp. 37–40, 2009.
- [29] OECD & FAO, *OECD-FAO Agricultural Outlook 2015-2024*.: Organisation for Economic Co-operation and Development, and Food and Agriculture Organization of the United Nations, 2015.

-
- [30] OVERPECK, JONATHAN T, GERALD A MEEHL, SANDRINE BONY, & DAVID R EAST-ERLING, ‘Climate Data Challenges in the 21st Century.’ *Science*, **331** (6018), pp. 700–702, feb, 2011.
- [31] RAIN AND HAIL INSURANCE SOCIETY, ‘2016 crop insurance update.’ Technical report, Rain and Hail Insurance Society, 2016.
- [32] RAO, KOLLI N, ‘Index based crop insurance.’ *Agriculture and Agricultural Science Procedia*, **1**, pp. 193–203, 2010.
- [33] RIPPEY, BRADLEY R., ‘The U.S. drought of 2012.’ *Weather and Climate Extremes*, **10**, pp. 57–64, 2015.
- [34] SAKAMOTO, T, M YOKOZAWA, H TORITANI, M SHIBAYAMA, N ISHITSUKA, & H OHNO, ‘A crop phenology detection method using time-series MODIS data.’ *Remote Sensing of Environment*, **96** (3-4), pp. 366–374, 2005.
- [35] SCHAEFER, GARRY L., MICHAEL H. COSH, & THOMAS J. JACKSON, ‘The USDA Natural Resources Conservation Service Soil Climate Analysis Network (SCAN).’ *Journal of Atmospheric and Oceanic Technology*, **24** (12), pp. 2073–2077, 2007.
- [36] SHIN, D. W., G. A. BAIGORRIA, Y. K. LIM, S. COCKE, T. E. LAROW, JAMES J. O’BRIEN, & JAMES W. JONES, ‘Assessing maize and peanut yield simulations with various seasonal climate data in the southeastern United States.’ *Journal of Applied Meteorology and Climatology*, **49** (4), pp. 592–603, 2010.
- [37] THE WORLD BANK, ‘WEATHER INDEX INSURANCE FOR AGRICULTURE : Guidance for Development Practitioners.’ Technical Report November, The World Bank, 2011.
- [38] THORNTON, P.E.; M.M.; THORTHON, B.W.; MAYER, N.; WILHELMI, Y.; WEI, R.; DEVARAKONDA, & R.B.; COOK, ‘Daymet: Daily Surface Weather Data on a 1-km Grid for North America, Version 2.’ 2014.
- [39] UNITED NATION, ‘World Population Prospects: The 2015 Revision.’ *United Nations Economic and Social Affairs*, **XXXIII** (2), pp. 1–66, 2015.
- [40] UNITED STATES DEPARTMENT OF AGRICULTURE (USDA), NATIONAL AGRICULTURAL STATISTICS SERVICE (NASS), RESEARCH AND DEVELOPMENT DIVISION (RDD), GEOSPATIAL INFORMATION, ‘USDA, National Agricultural Statistics Service, Cropland Data Layer for the United States.’ 2013.

-
- [41] VAPNIK, VLADIMIR N, *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag New York, Inc. 1995.
- [42] WARDLOW, B, S EGBERT, & J KASTENS, 'Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains.' *Remote Sensing of Environment*, **108** (3), pp. 290–310, 2007.
- [43] WILLIAMS, J R, C A JONES, & P T DYKE, 'A modeling approach to determining the relationship between erosion and soil productivity.' *Transactions of ASABE*, **27** (1), pp. 129–144, 1984.
- [44] XIE, Y., Z. SHA, & M. YU, 'Remote sensing imagery in vegetation mapping: a review.' *Journal of Plant Ecology*, **1** (1), pp. 9–23, apr, 2008.
- [45] YANG, Z, R MUELLER, & W CROW, 'US national cropland soil moisture monitoring using SMAP.' In *2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS.*, pp. 3746–3749, 2013.
- [46] ZHAO, L, J YANG, P LI, & L ZHANG, 'Characteristics Analysis and Classification of Crop Harvest Patterns by Exploiting High-Frequency MultiPolarization SAR Data.' *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7** (9), pp. 3773–3783, 2014.
- [47] 森下 興,『伸びる農業支える保険』, 保険教育システム研究所, 287 頁, 2014 年.
- [48] 多々納裕一,「災害リスクの特徴とそのマネジメント戦略」,『社会技術研究論文集』, **1**, 141–148 頁, 2003 年.

本研究に関する発表の一覧

査読付き論文

- Kuwata, K., Mhamood, F., Shibasaki, R., Weather index for crop insurance to mitigate basis risk, the International Geoscience and Remote Sensing Symposium 2015, Milan, Italy
- Kuwata, K., Shibasaki, R., Estimating crop yield with deep learning and remotely sensed data, the International Geoscience and Remote Sensing Symposium 2015, Milan, Italy
- Kuwata, K., Shibasaki, R., Estimating corn yield in the United States with MODIS EVI and machine learning methods, International Society for Photogrammetry and Remote Sensing 2016, Prague, Czech Republic

査読無し論文

- Kuwata, K., Sugimoto, K., Shibasaki, R., 2013, A study of estimating winter wheat yields by using satellite data assimilation with crop model, Asian Conference on Remote Sensing, Bali, Indonesia
- Kuwata, K., Shibasaki, R., Analysis of climate change impact on U.S. crop yields with reanalysis data, 2014 American Geographic Union, San Francisco, U.S.A

謝辞

本論文の研究を遂行するにあたり、多くの方の支援を賜った。

指導教員である柴崎亮介教授は、著者が修士として入学してから研究指導を下さり、研究を進める上で必要な基礎を築くことができた。また、修士課程から博士課程を通して、海外での学会参加や調査など、渡航に要する準備や費用などの多大なるご支援を頂いた。貴重な経験を積むことはもちろん、かけがえのない人脈を構築することができ、人生の大きな財産を得ることができた。修士課程修了後、民間会社で就職している間には、業務を発注して下さり、卒業後も研究開発に取り組む機会を与えてくださった。また、職場での悩みを打ち明けた際も、親身になって相談に乗って頂き、博士課程へ進学するきっかけとなった。

本研究の基幹技術である、地球環境情報統合プログラム Data Integration & Analysis System (DIAS) を利用する上で、研究実施機関の方々からは多大な支援を賜った。本研究で扱った大容量のデータを短時間で処理するためには、DIAS の存在なくして達成することはできなかった。

本論文の副査の先生方からはご多忙の中、貴重なご意見を多数いただいた。二宮正士教授は、農学や農業統計の専門的観点から本研究に貴重な知見を与えてくださった。竹内渉准教授は、リモートセンシング研究の先端に取り組む研究者かつ、一人の専門家として、あるべき姿や将来像についてご提示してくださった。布施孝志准教授は、プラハの学会中に研究面談をして下さり、本手法の核となる機械学習や本論文の全体に対して貴重なご意見やご指摘を賜った。川崎昭如准教授は、ご多忙の中、何度も個人的に面談をして下さり、本研究の有用性について重要なご意見を頂いた。

研究室の先輩である宮崎浩之氏は、修士課程在学中より、論文執筆をはじめとするあらゆる研究活動に対してアドバイスを頂くことができ、研究者として求められるプロフェッショナルの姿勢を示してくださった。また、衛星リモートセンシングを活用する研究に取り組む同じ研究者として、日々研究室で行った議論は、今後の研究活動に邁進するためのインスピレーションを掻き立てることができた。

研究室の研究員である大平亘氏は、研究室でのかけがえのない相談相手であった。リモートセンシングをはじめとするあらゆる研究テーマの議論から、海外経験など様々な事の議論を交わすことができた。

2013年に修士課程を修了した Faizan Mahmood 氏は、同じ研究テーマに取り組み、重要な研究成果を上げることができた。努力を惜しまない Mahmood 氏の直向きな姿勢を受け、著者も努力を惜しむことなく研究に取り組むことができた。

博士課程の同期として入学した小川芳樹氏は、博士論文提出期間に共に頑張った仲であり、

お互いを励まし合うことで論文執筆を完遂することができた。研究分野は異なるが、研究者としてそれぞれの研究を議論できたことは、貴重な体験である。研究室以外でも、スキー旅行やバリやプラハでの学会など世界中を共に旅をすることができ、博士課程在籍中に大切な思い出を作ることができた。

研究室の後輩である長谷川瑠子氏は、多数の講義と一緒に受講して多くの事を学ぶとともに、かけがえのない学生生活を送った。博士課程から社会基盤学専攻へ進学した著者は、専攻内に知人が少なく、不慣れな事が多々あったが、長谷川氏のおかげで、大学院生活を謳歌する事ができた。また、研究室の雰囲気作りに大きく貢献していただき、感謝を申し上げたい。

著者が所属する研究室の方々からも様々なご支援を賜った。関本義秀准教授は、ゼミの際に鋭い指摘や的確なご指導を承り、本研究を発展させるきっかけとなった。宴席では、研究室の方々との親睦を深めることができ、深い人間関係を築くことができた。秘書の秋枝久美子氏、本間理恵子氏、川端晴子氏には、研究活動に関する経理手続きなどのバックオフィス業務を担って頂いたおかげで、著者は研究活動に専念することができた。瀬戸寿一講師、秋山祐樹助教、須藤明人助教、小野雅史氏、金杉洋氏、福島祐樹氏、松原剛氏、小俣博司氏、新井亜弓氏、樫山武浩氏、宮澤聡氏、Ranjit Saurav、氏池澤俊氏、西本友香氏、和田健氏、矢部貴大氏、古澤京氏、前田紘弥氏は、取り組む研究テーマは違えど、互いに尊び刺激しあうことができただけでなく、私的な交流においても充実した時間を送ることができた。

東京大学産学協創推進本部の各務茂夫教授、加藤晴洋氏と宮脇守氏には、EDGEプログラムにおいて貴重な経験を積むきっかけを与えてくださった。これまで体験してこなかった、自らの研究テーマを事業化する研修プログラムを通して、研究を事業化することの重要性を認識することができた。さらに、シリコンバレーでの研修やピッチに取り組むことで、著者の今後の進路に対して大きな影響と刺激を得ることができた。

他にも数え切れないほどのご支援を賜ったが、何不自由なく、学位取得のために経済的、精神的な支えとなった家族に一番の感謝の意を申し上げたい。

皆様、どうもありがとうございました。

桑田 賢太郎 / Kentaro F. Kuwata